



João Filipe Santos Simões

Licenciado em Ciências de Engenharia Mecânica

Controlo de Condição de Componentes de Turbinas Eólicas

Dissertação para obtenção do Grau de Mestre em
Engenharia Mecânica

Orientador: Tiago Silva, Professor Auxiliar Convidado, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa

Co-orientadora: Alda Carvalho, Professora Adjunta, Instituto Superior de Engenharia de Lisboa, Instituto Politécnico de Lisboa

Júri

Presidente: Professor António Paulo Vale Urgueira
Arguente: Professora Cláudia Sequeira
Vogal: Professor Tiago Alexandre Narciso da Silva



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Março, 2018

Controlo de Condição de Componentes de Turbinas Eólicas

Copyright © João Filipe Santos Simões, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

"Intelligence is the ability to adapt to change."

- Stephen Hawking

Agradecimentos

Quero deixar umas sentidas palavras de agradecimento a todos os que tornaram este ciclo da minha vida possível, em particular:

- Ao professor Tiago Silva pela disponibilidade, correções, paciência, conselhos e sugestões que permitiram a conclusão desta dissertação.
- À professora Alda Carvalho pela orientação prestada.
- A toda a minha família e em especial aos meus pais que possibilitaram a realização deste curso.
- A todos os amigos criados durante estes anos na faculdade que por certo o continuarão a ser.
- A todos os amigos de longa data que sempre me apoiaram e me motivaram para a conclusão deste curso.

A todos, o meu sincero Obrigado!

Resumo

Energias renováveis estão cada vez mais a desempenhar um papel importantíssimo na produção de energia global, como alternativa a energias fósseis de modo a reduzir o impacto no ambiente e no aquecimento global. A energia eólica compõe actualmente 4 % da eletricidade global produzida.

Para tornar a energia eólica mais competitiva em relação a outras fontes de energia, a fiabilidade e tempo de vida são cruciais. Vários avanços na área de manutenção têm sido feitos nos últimos anos suportados pelo desenvolvimento tecnológico. Este avanço tecnológico permitiu que estratégias de manutenção como manutenção preventiva baseada na condição do componente fossem desenvolvidas e aplicadas para melhorar o funcionamento das turbinas e reduzir os custos de operação.

Baseando-se no princípio de que um aumento inesperado na temperatura dos componentes pode indicar funcionamento defeituoso e uma vez que grandes quantidades de dados de temperatura são facilmente adquiridas pelo sistema SCADA (*Supervisory Control and Data Acquisition*), é estudada uma relação entre dois parâmetros de funcionamento de uma turbina eólica, tais como a temperatura dos componentes e a velocidade de rotação do rotor, com o intuito de avaliar o estado do componente.

Esta dissertação apresenta uma técnica de controlo de condição baseada em dados obtidos através do sistema SCADA de um parque eólico português com o objectivo de encontrar um grau de deterioração dos componentes de uma turbina eólica e assim providenciar informações essenciais para um melhor planeamento de manutenção destas turbinas.

Palavras-chave: Manutenção, Falhas, Diagnóstico e Prognóstico, Controlo de condição, Turbina Eólica, Grau de deterioração.

Abstract

Renewable energies are increasingly playing an important role in global energy, as an alternative to fossil sources as a way to reduce the negative impact in the environment and global warming. Wind Turbines are one of the energy sources that have grown the most in the whole world in the past years and provide, nowadays, 4% of the global electricity.

In order to make wind energy more competitive relatively to other energy sources, the reliability and lifetime are crucial. Several advances in the maintenance field have been made in the past years supported by the technologic development. These technologic advances allowed maintenance strategies such as Condition-Based Maintenance (CBM) to be developed and applied in order to improve the operation of wind turbines and reduce the operating costs.

Based on the principle that an unexpected increase in the temperature of the components may imply malfunction and since large amounts of temperature data are easily acquired by the SCADA system (Supervisory Control and Data Acquisition), a relation between two operating parameters of a wind turbine, such as the temperature of the components and rotor speed, with the intent to evaluate the actual state of the component.

This manuscript presents a condition-based maintenance technique based on data obtained through the SCADA system of a Portuguese wind farm with the objective of finding a deterioration degree of the components of a wind turbine and thus provide essential information for better maintenance planning of these turbines.

Keywords: Maintenance, Failures, Diagnosis and Prognosis, Condition-based maintenance (CBM), Wind Turbine, Deterioration degree.

Índice

Lista de Figuras	xv
Lista de Tabelas	xvii
Lista de Símbolos e Acrónimos	xix
1 Introdução	1
1.1 Motivação	1
1.2 Objectivos	2
1.3 Estrutura	3
2 Enquadramento	5
2.1 Manutenção	5
2.1.1 Nota Introdutória	5
2.1.2 Tipos de manutenção	8
2.2 Controlo de Condição	10
2.2.1 Aquisição de dados	11
2.2.2 Processamento de dados	12
2.2.3 Tomada de decisão em Manutenção	13
2.2.4 Diagnóstico	14
2.2.5 Prognóstico	15
2.3 Energia Eólica	24
2.3.1 Turbinas Eólicas	25
2.3.2 Manutenção em Turbinas eólicas	27
2.3.3 Revisão Bibliográfica	30
3 Caso de Estudo	41
3.1 Descrição do Método em Estudo	42
3.2 Descrição do Parque e Turbinas	44

ÍNDICE

3.3	Análise Preliminar dos dados	46
3.4	Desenvolvimento e aplicação do Algoritmo	48
3.4.1	Desenvolvimento	48
3.4.2	Aplicação do Algoritmo	55
4	Conclusão	69
4.1	Trabalhos Futuros	70
	Bibliografia	71
A	Caso 3	83
B	Caso 4	89
C	Caso 5	95

Lista de Figuras

1.1	Custo/dia de paragem inesperada [4].	2
2.1	Relação entre tempo até à falha, fiabilidade e custo de manutenção [7]. . . .	6
2.2	Curva P-F [11].	7
2.3	Curva da banheira [13].	8
2.4	Passos de um sistema <i>CBM</i>	11
2.5	Diagnóstico e Prognóstico [21].	13
2.6	Histograma do número de publicações em prognóstico de máquinas nos últimos anos [34].	16
2.7	Gráfico Circular de publicações relacionadas às categorias acima referidas [34].	17
2.8	Ilustração de uma rede neuronal aritificial feedforward [40].	20
2.9	Ilustração de uma rede neuronal artificial feedback [50].	21
2.10	Comparação de uma abordagem clássica para fuzzy [57]	23
2.11	Evolução do aproveitamento da Energia Eólica.	24
2.12	Investimento (€ Milhões/ano) expéctavel em turbinas eólicas [73]	25
2.13	Crescimento e previsão das dimensões das turbinas [72]	25
2.14	Capacidade Total Instalada e prognóstico 1997-2020[MW] [74].	26
2.15	Falhas em turbinas de diferentes dimensões [78].	27
2.16	Diagrama do método co-integração aplicado [85].	31
2.17	Resultado do estudo [90].	34
2.18	Esquema do método de simulação [94].	36
2.19	Distância de Mahalanobis [104].	38
3.1	Sensores de temperatura [81].	42
3.2	Exemplo de caso de estudo [107].	44
3.3	Características da Turbina Eólica Nordex N90/2300.	45
3.4	Representação gráfica do resultado do algoritmo Fuzzy C-means (2 clusters).	50
3.5	Diagrama do cálculo de β_1 onde c corresponde ao número de clusters [107]. .	51
3.6	Demonstração gráfica da função Temp(n).	53

3.7	Histograma $Velocidade_{rotor}$	55
3.8	Histograma $Temperatura_{caixaVelocidades}$	56
3.9	Histograma da distribuição dos valores de $Velocidade_{rotor}$ pelos 12bins. . . .	57
3.10	Função $Temp(n) = 0.0589 * n^2 - 0.5445 * n + 58.2438$	58
3.11	Grau de deterioração	60
3.12	Grau de deterioração (regressão polinomial 2º grau).	61
3.13	Grau de deterioração ampliado.	61
3.14	Grau de deterioração ampliado.	62
3.15	Histograma $Velocidade_{rotor}$	63
3.16	Histograma $Temperatura_{componente}$	63
3.17	Histograma distribuição dos dados pelos bins.	64
3.18	Gráfico da função $Temp(n) = -0.1175 * n^2 + 6.184 * n + 6.55$	65
3.19	Gráfico deterioração Caso 2.	67
3.20	Regressão polinomial 2º grau Caso 2.	67
A.1	Histograma $Velocidade_{rotor}$	83
A.2	Histograma $Temperatura_{componente}$	84
A.3	Histograma distribuição dos dados pelos bins	84
A.4	Gráfico da função $Temp(n) = -0.1874 * n^2 + 6.5626 * n + 5.6116$	85
A.5	Gráfico deterioração Caso 3.	87
A.6	Regressão polinomial 2º grau Caso 3.	87
B.1	Histograma $Velocidade_{rotor}$	89
B.2	Histograma $Temperatura_{componente}$	90
B.3	Histograma distribuição dos dados pelos bins.	90
B.4	Gráfico da função $Temp(n) = -0.1070 * n^2 + 5.2538 * n + 12.8958$	91
B.5	Gráfico deterioração Caso 4.	93
B.6	Regressão polinomial 2º grau Caso 4.	93
C.1	Histograma $Velocidade_{rotor}$	95
C.2	Histograma $Temperatura_{componente}$	96
C.3	Histograma distribuição dos dados pelos bins.	96
C.4	Gráfico da função $Temp(n) = -0.0836 * n^2 + 4.5338 * n + 17.86$	97
C.5	Gráfico deterioração Caso 5.	99
C.6	Regressão polinomial 2º grau Caso 5.	99

Lista de Tabelas

3.1	Características Técnicas do Parque	44
3.2	Características Técnicas das Turbinas	45
3.3	Tabela Exemplo	52
3.4	Categorias do grau de deterioração.	54
3.5	Médias de $Velocidade_{rotor}$ e $Temperatura_{caixaVelocidades}$	57
3.6	Grupos de Turbinas (2 clusters) Caso 1	59
3.7	Grupos de Turbinas(3 clusters) Caso 1	59
3.8	Valores de média em cada bin	64
3.9	Grupos de Turbinas Caso 2	65
A.1	Valores de média em cada bin	85
A.2	Grupos de Turbinas Caso 3	86
B.1	Valores de média em cada bin	91
B.2	Grupos de Turbinas Caso 4	92
C.1	Valores de média em cada bin	97
C.2	Grupos de Turbinas Caso 5	98

Lista de Símbolos e Acrónimos

β_1 Limite Inferior Variável.

β_2 Limite Superior Variável.

R Número de registos.

d Número de bins.

g Grau de deterioração.

n Velocidade do rotor.

x Temperatura registada no momento.

ANFIS Adaptive neuro-fuzzy inference system.

CBM Condition-based Maintenance.

CM Condition Monitoring.

FFNN Feedforward Neural Network.

ML Machine Learning.

NF Neuro-fuzzy.

RNAs Redes Neurais Artificiais.

RNN Recurrent Neural Network.

RUL Remaining Useful Life.

SCADA Supervisory Control and Data Acquisition.

TBM Time-based Maintenance.

Introdução

1.1 Motivação

A indústria moderna tem vindo a enfrentar um aumento exponencial na necessidade de produzir bens de alta qualidade e em maior quantidade, num ambiente seguro e tomando em conta os riscos ambientais mantendo os seus níveis operacionais com rendimento máximo.

O desenvolvimento tecnológico resultou numa maior complexidade tanto em máquinas industriais como em sistemas de produção, sistemas estes compostos por inúmeras fases e componentes, sujeitos a múltiplos acoplamentos e dependências físicas e lógicas entre si. A fiabilidade operacional destes complexos sistemas tem uma influência significativa na competitividade e rentabilidade das empresas industriais e respectivas nações.

Falhas inesperadas que ocorrem durante o tempo de produção resultam em sérias implicações negativas tais como um aumento do tempo de inactividade, baixa produtividade e por vezes riscos ambientais e de segurança. Isso faz com que a importância de estratégias de manutenção de máquinas, de processos de produção e sistemas da indústria seja maior. Este desenvolvimento tecnológico exigiu também que novos progressos fossem feitos na área de manutenção.

A manutenção pode aumentar a fiabilidade, qualidade de produção e o aumento da produtividade, assumindo todos os requisitos de segurança. No entanto, a opinião geral é de que “ A manutenção é um mal necessário” ou que “ Nada pode ser feito para melhorar os custos de manutenção”, no entanto, ao longo dos últimos anos essa frase passou a estar obsoleta. É verdade que o custo de manutenção contribui em grande parte no resultado global de operação e produção na indústria, no entanto, o montante investido em boas estratégias de manutenção pode possibilitar um retorno positivo ainda maior, tendo em conta que proporcionará um menor tempo de paragem de produção, logo melhor eficiência, contribuindo, deste modo, que os resultados globais das empresas sejam melhorados

através da manutenção. Na União Europeia 10% do Produto Interno Bruto é utilizado em manutenção [1]. Além disso, com o aumento da automação e mecanização e correspondente adaptação da indústria, que está cada vez mais equipada com equipamentos de controlo automático e menos mão de obra, os custos de manutenção têm aumentado substancialmente [2].

Consequentemente, é necessário encontrar e implementar uma sensata e eficaz estratégia de manutenção de modo a que os custos de manutenção possam atingir valores mínimos mantendo a produtividade máxima, contribuindo para os resultados positivos das organizações.

1.2 Objectivos

Na eventualidade de uma falha não expectável, as consequências económicas de uma paragem inesperada, podem chegar a valores entre 100.000€ até 200.000€ por dia na indústria[3]. A Figura 1.1 apresenta algumas implicações económicas de um dia de paragem não planeada.

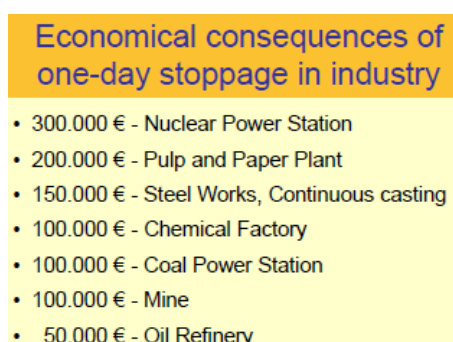


Figura 1.1: Custo/dia de paragem inesperada [4].

Uma vez que os custos de manutenção de máquinas industriais e sistemas de produção têm enorme influência nos custos finais de operação e numa era em que a oferta e competitividade aumenta a cada dia, é necessário assegurar que a manutenção exercida é a mais acertada, isto é, que relação custo-eficácia é a melhor.

A indústria actual exige sofisticadas e consequentemente dispendiosas estratégias de manutenção. O valor investido em manutenção na Europa era cerca de 1500 biliões de Euros anuais há cerca de 10 anos atrás [5], valor este, que por certo terá subido até aos dias de hoje. No entanto nem todo este valor investido em manutenção demonstra resultados convincentes. Por exemplo nos EUA o valor utilizado para manutenção era de 1.2 Biliões de Dólares, sendo que desse valor, entre 30% e 50% é gasto numa manutenção ineficiente. Já o estudo conduzido pelo *Department of Trade and Industry* no Reino Unido(UK) revelou

que uma fraca e ineficaz manutenção custa à sua indústria 1.3 biliões de libras por ano[5]. Havia portanto, uma urgente necessidade de melhorar técnicas e estratégias de manutenção.

Deste modo tem havido uma notável evolução das estratégias de manutenção. De uma manutenção corretiva e manutenção preventiva sistemática para uma manutenção preventiva condicionada(Condition-based Maintenance (CBM)) sendo sobre a qual esta dissertação incidirá.

Esta dissertação tem como objectivo apresentar e discutir os avanços feitos em *CBM*, nomeadamente a utilização de inteligência artificial como Machine Learning (ML). Será também apresentado um caso de estudo aplicando uma técnica *CBM* desenvolvida em *MATLAB* utilizando um bloco de dados adquiridos através do sistema Supervisory Control and Data Acquisition (SCADA) de um parque eólico português com objectivo de testar um método de manutenção preventiva condicionada eficaz no sector de energia eólica. O método desenvolvido pretende encontrar um grau de deterioração de um componente, revelando o seu estado actual, e assim, poder avaliar qual o procedimento mais adequado de manutenção a seguir, evitando falhas inesperadas e tempos de paragem não planeados. Isto permitirá não só que o montante investido em manutenção reduza, assim como numa produção de energia mais eficiente, resultando deste modo, numa melhoria dos resultados globais do parque eólico.

1.3 Estrutura

O documento está organizado em 4 capítulos. Sendo o Capítulo 1 uma breve introdução ao tema, assim como a motivação e os objectivos propostos.

O Capítulo 2 apresenta um enquadramento do tema, estado da arte, revelando vários estudos e investigação na área, bem como alguns exemplos práticos e softwares desenvolvidos. No Capítulo 3 é explicado o método em estudo e nos princípios em que se baseia, assim como o trabalho utilizado como ponto de partida para esta dissertação. Utilizando como base de dados, os dados SCADA de um parque eólico português, são desenvolvidas ferramentas em Matlab com intuito de avaliar o grau de deterioração de um componente, relacionando os seus valores de temperatura e de velocidade do rotor. Também neste capítulo, diferentes abordagens são tomadas com o objectivo de perceber melhor os resultados obtidos, e assim, poderem ser retiradas as melhores ilações.

Por fim, no Capítulo 4 são resumidas as conclusões do estudo elaborado, reflexões do método proposto e outros apresentados, assim como uma expectativa futura quanto à *CBM*. São também apresentadas sugestões para aplicações futuras do algoritmo desenvolvido assim como outros métodos apresentados que poderão contribuir para o crescimento de produção de energia eólica.

Enquadramento

2.1 Manutenção

2.1.1 Nota Introdutória

Com o rápido desenvolvimento tecnológico, os produtos têm-se tornado mais complexos não deixando de exigir alta qualidade e fiabilidade. A fiabilidade sempre foi um importante aspecto na avaliação de produtos ou equipamentos industriais. O design do produto é, obviamente, essencial para produtos com alta fiabilidade, no entanto, apesar de quão bom o design possa ser, certo é que o produto irá sofrer deterioração ao longo do tempo visto que estará a operar sobre determinadas cargas de tensão ou compressão num ambiente operacional, muitas vezes envolvendo factores aleatórios.

A manutenção foi então introduzida, como uma estratégia eficiente para assegurar um nível satisfatório de fiabilidade durante a vida útil de um produto, “Manutenção é necessária para assegurar que os componentes funcionem correctamente para aquilo que foram projectados” [6]. Todos estes factores fazem com que o investimento em manutenção não pare de aumentar. Eventualmente, a manutenção tornou-se numa importante despesa ou investimento do universo industrial. A Figura 2.1 demonstra a relação entre o custo de manutenção, fiabilidade e tempo até à falha.




Figura 2.1: Relação entre tempo até à falha, fiabilidade e custo de manutenção [7].

A mais antiga técnica de manutenção conhecida é a manutenção correctiva, onde não são tomadas quaisquer medidas até que o equipamento parta ou sejam identificadas falhas e reparação ou substituição sejam necessárias. Para prevenir falhas catastróficas e paragens de emergência, a manutenção preventiva sistemática é introduzida por volta de 1950 [8], definindo intervalos periódicos nos quais é realizada manutenção, independentemente do estado da máquina. Contudo, esta nova política de manutenção acabou por não ser tão bem recebida quanto esperado. Ainda que reduzindo avarias dos equipamentos, exige um maior trabalho de manutenção, não elimina falhas catastróficas e muitas das vezes acaba por ser feita manutenção desnecessária, podendo por esta via a manutenção contribuir para o aparecimento de novas falhas.

Assim, estratégias de manutenção preventiva mais eficientes como manutenção preventiva baseada na condição do componente (*CBM - Condition-Based Maintenance*) têm sido desenvolvidas. Foi revelado que 99% das falhas são precedidas por indicadores perceptíveis [9]. *CBM* tenta acompanhar a vida útil do componente (*Remaining Useful Life (RUL)*) baseando-se no controlo de condição sem interromper o normal funcionamento do mesmo. Quando utilizado propriamente pode reduzir significativamente os custos de manutenção.

Ao longo dos últimos anos, tecnologias em controlo de condição (*Condition Monitoring (CM)*) e diagnóstico de falhas têm sido desenvolvidas. Dados como registos de vibração e ruído, análise de lubrificantes, entre outros, podem ser adquiridos, processados e analisados por sensores mais evoluídos, software de bases de dados e novas tecnologias computacionais. No entanto, novas tecnologias por norma permitem ter acesso a novos tipos de informação que ainda não foram totalmente explorados. Este desenvolvimento apresenta um desafio enorme para a comunidade científica, no que toca à filtragem e

interpretação de dados e qual a sua relevância para as técnicas de manutenção.

Um importante princípio *CBM* é a *P-F curve*, que pode ser utilizada para estimar *RUL* de um componente [10]. A Figura 2.2 ilustra como um elemento sofre deterioração ao longo do tempo até ao ponto que se torna detectável (Ponto P). Consequentemente, se não for detectada e acções não forem tomadas, continuará a sofrer deterioração (a uma taxa de aceleração maior) até atingir o ponto de ruptura (Ponto F).




Figura 2.2: Curva P-F [11].

Outra das curvas importantes de *CBM* que merece menção é a curva da banheira ou *bathtub curve* [12]. Esta curva, apresentada na Figura 2.3, representa a fiabilidade de um componente ao longo do seu ciclo de vida.

Demonstra que um elemento no início do seu ciclo de vida apresenta uma maior probabilidade de falha devido a erros no seu projecto ou falhas na sua instalação/aco-
plamento. Estas falhas são conhecidas como falhas prematuras e por norma ocorrem nas primeiras semanas de operação. Após este período, a probabilidade de falha diminui con-
sideravelmente por um período relativamente longo, conhecido como o período de vida útil. Por fim, e devido ao desgaste acumulado durante os 2 períodos anteriores o elemento chega ao final do seu tempo de vida útil e a probabilidade de falha vai aumentando. Este período é conhecido como final de vida útil ou de desgaste.

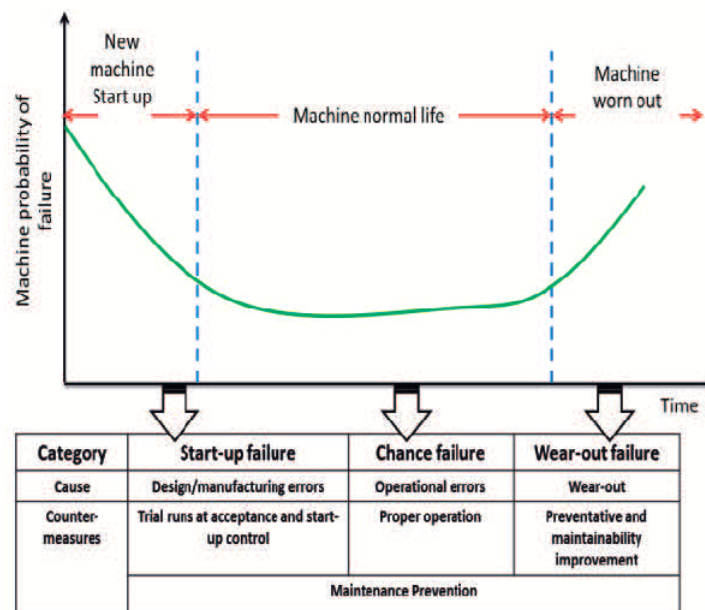


Figura 2.3: Curva da banheira [13].

2.1.2 Tipos de manutenção

Como referido anteriormente, a necessidade de melhorar a eficiência das empresas e os seus resultados, levou a que diversas técnicas de manutenção fossem desenvolvidas e testadas de acordo com as especificações e necessidades de cada empresa, podendo dividi-las em 3 categorias:

- Manutenção Correctiva
- Manutenção preventiva sistemática (*TBM*)
- Manutenção preventiva condicionada (*CBM*)

Manutenção Correctiva - Método tradicional onde apenas se toma uma acção após avaria. Este método apresenta como grande vantagem, utilizar o máximo de tempo de vida útil de um componente. No entanto, não evita falhas catastróficas que podem levar a sérios danos. Na eventualidade de uma falha, o tempo de paragem e reparação pode ser bastante grande, incluindo o tempo necessário para substituição de componentes, desde o tempo de encomenda, envio e, no caso de componentes principais, pode mesmo ser necessária a sua produção.

Deste modo, e como os sistemas de produção são cada vez mais evoluídos e dependentes de todos os seus componentes, o maior prejuízo acaba por ser na perda de produção que na maioria das vezes é mais elevado que o próprio custo da máquina. Ainda assim, existem certos tipos de indústria onde a produção em série não está tão representada e é

composta por várias máquinas singulares, como máquinas de costura, onde a avaria de uma das máquinas não é crítica para a produção e os perigos de avaria são mínimos.

Manutenção preventiva sistemática - Também conhecida como manutenção baseada no tempo (Time-based Maintenance (TBM)) adopta uma estratégia em que alguma manutenção como lubrificação, remodelação, calibração e inspeção de equipamentos é feita periodicamente. O objetivo desta estratégia é diminuir os processos de deterioração que levam a falhas ou avarias. A manutenção preventiva sistemática pressupõe que o tempo médio entre falhas do equipamento é estatisticamente ou experientalmente conhecido e que o sistema se vai degradando normalmente com a utilização.

TBM inclui algumas paragens planeadas para reparações ou substituições previamente agendadas. Isto pode prevenir algumas avarias substituindo componentes críticos num sistema, em intervalos regulares embora mais curtos que o seu tempo de vida útil expectável. Inspeções de sistemas e substituição de componentes críticos em intervalos fixos de tempo é amplamente adoptada em produções automatizadas e controlo de sistemas. Embora *TBM* possa reduzir a probabilidade de falhas do sistema e a frequência de reparações de emergência não planeadas, não consegue eliminar completamente avarias aleatórias. Nas estratégias de manutenção preventiva sistemática maioria das decisões são feitas por especialistas experientes, por sugestão dos fabricantes, histórico de avarias, experiência operacional e julgamento de técnicos de manutenção.

Em aspectos económicos, *TBM* acaba por ser muito conservadora, visto que independentemente do estado real do componente são agendadas paragens ou reparações desnecessárias, ou seja, desperdício, que resulta em elevados custos de manutenção. Algumas praticas de *TBM* podem também estar desactualizadas e falharem em satisfazer o requisito operacional real da indústria moderna.

Manutenção preventiva condicionada - *CBM* é a estratégia de manutenção que aconselha acções de manutenção baseando-se na recolha de dados por processos de controlo de condição. Introduzida em 1975 com o objectivo de maximizar a eficácia da manutenção preventiva, evitando acções de manutenção desnecessárias, realizando-as apenas quando há evidências de comportamento anormal de determinado elemento.

O coração de *CBM* é o controlo de condição onde registos são sistematicamente monitorizados utilizando certos tipos de sensores ou outro tipo de indicadores. O estado do equipamento pode ser medido em vários parâmetros como vibração e ruído, temperatura, lubrificação, entre outros. Deste modo, actividades de manutenção são realizadas apenas quando necessário ou muito perto da avaria. No entanto esta técnica, encontrou algumas barreiras iniciais, nomeadamente a limitação no que diz respeito a técnicas de monitorização e recolha de dados. De qualquer modo, com a evolução tecnológica e contínua investigação na área, tornou-se na estratégia de manutenção mais indicada e procurada pelas empresas, uma vez que se devidamente utilizada, pode reduzir significativamente

os custos de manutenção, diminuindo o número de intervenções de manutenção sistemática desnecessárias ou de paragens de emergência e longos períodos de inactividade [14].

Resumindo, o objectivo da manutenção preventiva condicionada é realizar em tempo real uma avaliação das condições do equipamento para posterior avaliação e decisão da necessidade de manutenção, reduzindo manutenção desnecessária e custos relacionados [15].

2.2 Controlo de Condição

Monitorização é definida como “ uma actividade que observa o estado atual de um elemento” [16], noutras palavras, controlo de condição é uma ferramenta utilizada para indicar a condição do equipamento ou sistema. Com os principais objectivos de recolher dados da condição do equipamento e aumentar o conhecimento das causas de avaria, no sentido de definir padrões de deterioração do equipamento.

O controlo de condição pode ser realizado de 2 maneiras: *on-line* e *off-line*. *On-line* é durante o ambiente operacional havendo por isso um *feedback* constante e *off-line* em que os dados recolhidos em certos intervalos de tempo são guardados para posterior consulta. Adicionalmente pode ser periódico ou contínuo. De um modo geral, monitorização periódica é feita em certos intervalos de tempo, como por exemplo de hora a hora, no final de cada turno, etc. auxiliados por equipamentos de medição manuais, desde aparelhos de medição de vibração e ruído até observações a olho nu por parte dos trabalhadores. Já monitorização contínua, como o nome indica, é realizada de forma contínua e automática, baseando-se em equipamentos especializados de medição como sensores.

Como em tudo, existem sempre alguns pontos negativos. No caso de monitorização contínua os custos são mais elevados visto que equipamentos especiais são necessários e podem ser registadas informações imprecisas no tratamento de dados devido ao enorme volume de dados. Por outro lado, a monitorização periódica apesar de mais barata, corre o risco de perder informação relevante entre os intervalos de monitorização [14].

Um sistema de controlo de condição consiste em 3 processos fundamentais:

1. Aquisição de dados (colheita de informação).
2. Processamento de dados (filtragem e análise de dados).
3. Tomada de decisão de manutenção (recomendação de acções a tomar através de diagnósticos ou prognósticos).

Uma esquematização da sequência dos processos pode ser vista na Figura 2.4.




Figura 2.4: Passos de um sistema *CBM*.

Independentemente de qual técnica *CBM* aplicada, os dados da condição do equipamento precisam de ser filtrados, interpretados e medidas apropriadas devem ser tomadas de acordo. Actualmente, é maioritariamente apoiada numa selecção manual de características padrão ou definidas por especialistas, o que implica, inevitavelmente, que algumas características sejam definidas sem conhecimento explícito sobre as configurações, estado e modos operativos de cada máquina em particular. É aqui que novas tendências do mundo tecnológico como *machine learning* (ML) e *data mining* (DM) nos podem trazer grandes contributos [17].

2.2.1 Aquisição de dados

A aquisição de dados é um processo de colheita e armazenamento de dados de um sistema para controlo de condição, diagnosticar falhas e fazer o prognóstico dos futuros estados do componente e a sua vida útil. É composto por sensores, aparelhos de transmissão de dados e de armazenamento. A aquisição de dados é um dos passos fulcrais de *CBM* uma vez que é nele que se baseiam todos os passos que se seguem.

Dados utilizados para *CBM* podem ser divididos em dois tipos: dados de eventos e dados de controlo de condição. Apesar de por vezes os dados de eventos serem negligenciados, ambos apresentam semelhante importância no que diz respeito à colheita de informação [18]. O primeiro refere-se a informações sobre que tipo de evento houve (instalação, falha, avaria, etc.) e o que foi feito (reparação, substituição, mudança de óleo, etc.). O segundo, a dados relacionados com o estado actual do equipamento, tais como, vibração e ruído, análise de óleos, temperatura, pressão, humidade, etc.

Uma variada gama de sensores, entre os quais, acelerómetros, micro-sensores, sensores ultrasonicos, sensores de ruído, infra-vermelhos, etc. são aplicados para recolha de diferentes tipos de informações. Com a rápida evolução dos computadores e avançada tecnologia de sensores, a tecnologia de aquisição de dados tem-se tornado cada vez mais poderosa e menos dispendiosa [19].

Atenta a este cenário, a indústria moderna tem vindo a aplicar vários sistemas de aquisição de dados como *SCADA* (*Supervisory Control and Data Acquisition*) e *CMS* (*Condition Monitoring System*). No entanto, é difícil obter dados de ambiente operacional até à falha, de alta qualidade, para propósitos de investigação académica. Isto deve-se a alguns factores, como por exemplo:

- Degradação de máquinas pode demorar bastantes meses ou mesmo anos, tornando a aquisição de dados até à falha mais dispendiosa visto que são processos de longa duração.

- Num ambiente industrial, praticamente não é permitido que os componentes alcancem situações de falhas críticas, uma vez que podem levar à total destruição da máquina ou a acidentes catastróficos.

- Máquinas como turbinas eólicas, motores de aviação e de automóveis, com as suas respectivas diferenças e graus de segurança, funcionam muitas vezes em ambientes hostis, o que leva a interferências devido a factores exteriores e diminui a qualidade dos dados.

- Algumas instituições militares e comerciais que têm acesso a este tipo de dados estão reticentes quanto a partilha dos mesmos por motivos de segredo militar ou de competição comercial. Por isso, apenas algumas instituições privilegiadas, têm acesso a esses dados.

Devido aos factores acima referidos, maioria dos estudos e investigação são baseados em dados de experiências laboratoriais ao invés de um ambiente real industrial [19].

2.2.2 Processamento de dados

O primeiro passo de processamento de dados é a filtragem. É um passo importante pois por norma, qualquer bloco de dados contém imprecisões. Imprecisões essas que podem ser causados por vários factores nomeadamente erros humanos e falhas dos sensores, cujo trabalho desenvolvido por R.Xu e C.Kwan permite ajudar [20]. No entanto, não existe uma maneira simples de filtrar dados. Por vezes requer verificação humana, outras a utilização de ferramentas gráficas, etc. De facto a filtragem de dados por si só é uma vasta área dentro da qual existem inúmeros estudos e alternativas.

O passo seguinte é a análise de dados. A variedade de modelos, algoritmos, ferramentas, dependendo do tipo de dados disponíveis, para análise de dados é enorme. O tipo de dados adquiridos podem ser inseridos em 3 categorias:

- Valores Pontuais (*Value type*). São registados valores pontuais para cada tempo específico. Análise de óleos, temperatura, pressão, são exemplos deste tipo de dados.

- Funções contínuas (*Waveform type*). Os dados são registados em função do tempo, como por exemplo, dados de vibração e ruído, apresentando uma forma de onda.

- Multi-dimensionais, como o nome indica, os dados são recebidos em formato dimensional, por exemplo, dados de imagem como, imagens raio-x, termógrafos infravermelhos.

2.2.3 Tomada de decisão em Manutenção

O último passo de *CBM* é a tomada de decisão. A quantidade e qualidade de suporte para as decisões de manutenção são cruciais.

Diagnóstico e prognóstico são dois aspectos importantes no auxílio de tomada de decisão e consequentemente de um sistema de controlo de condição. Com o aumento da automatização e mecanização, softwares de diagnóstico e prognóstico tornaram-se numa ferramenta fundamental para a decisão de acções de manutenção, sendo até previsível virem a substituir especialistas de manutenção no futuro.

Diagnóstico é responsável pela detecção, localização e identificação da falha quando esta ocorre. Prognóstico consiste na previsão de falhas ou degradação do componente antes destas ocorrerem, ou seja o tempo de vida útil do componente (*RUL*) [8]. Diagnóstico é portanto, uma análise posterior enquanto prognóstico é uma análise prévia. A Figura 2.5 proporciona a visualização da diferença entre ambas.




Figura 2.5: Diagnóstico e Prognóstico [21].

2.2.4 Diagnóstico

Várias técnicas têm sido propostas com o propósito de identificar e detectar falhas e no seu diagnóstico. As abordagens mais comuns para o diagnóstico de falhas são:

- Métodos matemáticos
- Métodos baseados no conhecimento
- Métodos de reconhecimento de padrões

Métodos Matemáticos

São métodos que tentam o diagnóstico de falhas baseando-se em métodos analíticos onde a consistência entre os registos/dados e o comportamento expectável de um sistema são revistos analiticamente. Estes modelos podem ser modelos matemáticos com influencia da Física ou modelos matemáticos específicos da máquina a avaliar.

Métodos como filtros de Kalman, identificação de sistemas e relações de paridade são utilizados para a obtenção de sinais, chamados resíduos, que são indicativos de falhas na máquina.

Por fim, os resíduos são avaliados para detectar, isolar e identificar a falha. Alguns métodos foram aplicados com sucesso no diagnóstico de componentes mecânicos, tais como caixa-de-velocidades, rotores e rolamentos [22, 23].

Métodos baseados em conhecimento

Ou sistemas especializados baseiam-se na análise de dados de controlo de condição *on-line* de acordo com um conjunto de normas determinadas por conhecimento de especialistas. Este conhecimento inclui a localização de variáveis de processo, padrões de condições anormais de processos, sintomas de falhas, restrições operacionais e critérios de desempenho.

Aqui o conhecimento e inteligência dos operadores ou engenheiros podem ser implementados, o que pode ajudar no reconhecimento de potenciais falhas baseado em experiências anteriores. Esta abordagem pode reduzir a dificuldade em informações numéricas e automatizar a inteligência humana para supervisão do sistema. Algumas publicações [24–27] demonstram as suas aplicações.

Comparativamente ao método anterior, esta abordagem é particularmente adequada para grandes indústrias, visto que é capaz de reduzir a complexidade ao implementar o sistema de segurança correspondente, tornando-o flexível, fácil de entender e utilizar. A junção de métodos baseados no conhecimento com a recolha de dados em tempo real

permite melhorar a eficiência e fiabilidade na detecção de falhas e consequentemente a eficácia do sistema [28].

Métodos de reconhecimento de padrões

É um processo de mapeamento das informações obtidas e identificação de amostras similares. Tradicionalmente, o reconhecimento de padrões é feito manualmente por ferramentas gráficas auxiliares, como gráfico de espectro de potência, gráfico de espectro de fase, espectro-grama, gráfico de fase *wavelet*, etc.

No entanto, o reconhecimento manual de padrões requer experiência na área específica de diagnóstico. Assim, pessoal altamente treinado e qualificado é necessário. Portanto, o reconhecimento automático de padrões é extremamente desejável. Isto pode ser conseguido através da classificação de dados com base na informação recolhida dos sensores ou outras ferramentas de controlo de condição.

Este método, que inclui técnicas de inteligência artificial, tem sido cada vez mais aplicado na área de diagnóstico e tem mostrado um desempenho superior relativamente aos apresentados anteriormente [29–33]. No entanto, visto que é uma área recente ainda a ser desenvolvida e onde bastantes estudos e investigações têm sido feitas nos últimos anos, não é de momento tão fácil de aplicar como o desejado.

2.2.5 Prognóstico

Prognóstico tem como grande vantagem a capacidade de poder permitir a um sistema um tempo de inatividade nulo ou muito perto disso. No entanto, diagnóstico é necessário quando o prognóstico falha e uma avaria acaba por ocorrer. Assim sendo, o diagnóstico e o prognóstico acabam por estar muitas vezes interligados, até porque grande parte das vezes utilizam como base o mesmo bloco de dados. Um sistema *CBM* pode então ser composto por técnicas de diagnóstico, prognóstico ou ambas.

Prognóstico promete reduzir significativamente o tempo de inatividade, a necessidade de variadas peças em *stock*, custos de manutenção e falhas catastróficas. Contudo, prognóstico é uma área relativamente nova e por esse mesmo motivo, existe grande margem de progressão e interesse na investigação, tendo o número de publicações nesta área crescido ao longo dos últimos anos, como podemos ver pela Figura 2.6.




Figura 2.6: Histograma do número de publicações em prognóstico de máquinas nos últimos anos [34].

Apenas recentemente têm sido desenvolvidos algoritmos para *CBM* e despertado grande interesse na comunidade ligada à manutenção. Todavia, grande maioria desses algoritmos são desenvolvidos para aplicações específicas ao invés de modelos genéricos. Os sectores aeroespacial, automóvel, nuclear, controlo de sistemas, têm sido dos que mais têm investido na sua investigação e evolução [7].

Existe uma grande quantidade de estudos onde se tenta dividir os métodos de previsão de tempo útil de vida de um componente (*RUL*) ou de prognóstico numa grande gama de categorias [34], no entanto, com o intuito de simplificar e resumir, nesta dissertação serão classificados em apenas três:

- Modelos baseados em Física (*Physics based prognosis models*)
- Modelos baseados em Dados (Estatística e Inteligência Artificial) (*Data driven prognosis models*)
- Modelos híbridos (junção das anteriores) (*Hybrid models*)

O gráfico circular (Figura 2.7) demonstra as publicações relacionadas às categorias de métodos de previsão de tempo útil de vida de um componente (*RUL*), mencionadas no trabalho de Lei et al [34].




Figura 2.7: Gráfico Circular de publicações relacionadas às categorias acima referidas [34].

Modelos baseados em Física

Modelos baseados em física envolvem, tipicamente, o desenvolvimento de modelos matemáticos ligados a processos físicos, que têm influência directa ou indirecta na condição do componente. Os parâmetros utilizados nestes modelos estão relacionados com as propriedades do material, que são normalmente identificadas através de métodos experimentais, análise de elementos finitos ou outras técnicas adequadas. Estes modelos tentam combinar conhecimento mecânico do sistema em particular, fórmulas de previsão de defeitos e dados de controlo de condição para providenciar um resultado eficiente com conhecimento enriquecido.

Modelos baseado em física permitem uma precisa estimativa de tempo de vida útil, se o modelo for desenvolvido com total conhecimento dos mecanismos de deterioração e estimativas eficientes de parâmetros. Para alguns sistemas mecânicos mais complexos no entanto, cuja dificuldade em perceber os processos físicos relacionados à deterioração é maior, as aplicações deste tipo de modelos são mais restringidas.

A Lei de Paris-Erdogan (*PE*) é um dos modelos mais utilizados. Inicialmente proposta por [35] para descrever a propagação de fracturas, serviu de base para o desenvolvimento de vários estudos sendo aplicada à área de manutenção, nomeadamente de prognóstico [36]. Lei et al. [37] transformou o modelo *PE* num modelo empírico para estimativa de tempo de vida útil. Sun et al. [38] evoluiu a lei de *PE* para um modelo espaço-estado (*state-space model*).

Para a maioria das aplicações na indústria, prognósticos baseados em modelos físicos podem não ser a solução mais prática, uma vez que o tipo de falhas em questão pode ser única de componente para componente e é difícil de identificar sem interromper a

operação. No entanto, pode muito bem ser a abordagem mais apropriada para aplicações cuja precisão seja imprescindível e em que os modelos físicos sejam consistentes, como por exemplo em veículos aéreos [39]. Por norma, necessitam também de menos data que os modelos baseados em dados.

Modelos baseados em Dados

Modelos baseados em dados tentam desenvolver modelos directamente a partir da aquisição de dados de controlo de condição ao invés de modelos baseados na física do sistema e no conhecimento de especialistas. São desenvolvidos tendo em conta o historial de eventos com o objectivo de prever degradações futuras. Sendo que depende fortemente dos dados e que estes por norma apresentam características distintas perto do momento de avaria, este tipo de modelos são poderosos no que diz respeito à previsão da condição de um componente num futuro próximo, especialmente perto do momento de falha/ruptura [40].

Estes modelos conseguem processar uma vasta gama de tipos de dados e explorar as nuances que não conseguem ser identificadas por outros tipo de modelos. O método de prognóstico baseado em dados tem como maiores pilares técnicas de estatística e de inteligência artificial (*machine learning ou data mining*) [28], dentro das quais, maioria provém da teoria de reconhecimento de padrões. Os métodos de modelos baseados em dados podem então ser classificado em duas categorias: Estatísticos e *Machine Learning*.

A abordagem estatística, estima a vida útil de um componente estabelecendo modelos estatísticos baseados em conhecimento empírico e geralmente apresenta uma previsão de resto de vida útil como uma condicionante de funções de densidade probabilidade (PDF) dependendo das observações [41]. Aqui, os modelos de previsão de tempo de vida útil são desenvolvidos enquadrando observações disponiveis em modelos de coeficientes aleatórios ou modelos de processos estocásticos sob métodos de probabilidade, sem dependerem de qualquer física ou princípio [34]. Variações aleatórias são geralmente introduzidas em parâmetros para descrever as incertezas devido a diferentes tipos de origem de variáveis, como o tempo, de unidade para unidade (*unit-to-unit*) e unidade de medida [42].

Assim, a abordagem estatística em modelos baseados em dados é eficiente em descrever a incerteza do processo de degradação e a sua influência na previsão da vida útil do componente. Tornou-se numa das mais populares abordagens dentro de todos os modelos de prognóstico como podemos concluir pela Figura 2.7.

Dentro da abordagem estatística, os modelos que mais têm chamado à atenção são os

modelos de Processo de Wiener [43], Modelo oculto de Markov [44], regressão do Processo Gaussiano (PG) [45], modelos de coeficientes aleatórios (*random coefficient models*) [46] entre outros.

Algumas publicações relacionadas às técnicas utilizadas nesta abordagem estatística de modelos baseados em dados têm sido realizadas tentando fazer um apanhado dos trabalhos desenvolvidos [34, 41, 43].

Já no campo de *machine learning*, a ideia passa por utilizar computadores para simular o cérebro humano e a aprendizagem permitindo-lhes que identifiquem e adquiram conhecimento do mundo real, melhorando o seu desempenho com base neste conhecimento [47]. Inserido na área de manutenção, *ML* propõe que o computador aprenda padrões de degradação do sistema, com técnicas de *machine learning* utilizando o bloco de dados disponível, sem a necessidade de recorrer a modelos de física ou estatística. É capaz de lidar com sistemas mecânicos complexos cujos processos de degradação são de difícil interpretação pelos modelos anteriores. Deste modo, é um campo que tem atraído cada vez mais atenção na área de prognóstico.

No entanto, os resultados obtidos através de *machine learning* são difíceis de ser explicados devido à falta de transparência, o que lhes dá o nome de “*black boxes*”. As técnicas de machine learning mais utilizadas são Redes Neurais Artificiais (RNAs) e sistemas de lógica *fuzzy*.

Redes Neurais Artificiais (RNAs) ou *Artificial Neural Network (ANN)* baseiam-se no mecanismo do cérebro conectando vários nós numa estrutura complexa de determinadas camadas. São uma das técnicas de *machine learning* mais aplicadas no campo de CBM. Aceitam a introdução de parâmetros (*inputs*), processam-nos e produzem parâmetros finais (*outputs*) de acordo com uma função de transferência não linear. Estes parâmetros têm de ser ajustados de modo a proporcionar o melhor desempenho possível. Ajustamento esse, que é feito tipicamente expondo a rede a um conjunto de exemplos, observando a resposta da rede para, por fim, re-ajustar os parâmetros de modo a minimizar o erro.

A rede é então treinada para obter um determinado output desejado, como por exemplo o grau de degradação ou o restante tempo de vida útil, reagindo aos inputs fornecidos, como o tempo e dados de controlo de condição. Várias técnicas podem ser aplicadas neste ajustamento ou para “treinar” estes parâmetros [48]. Podem também ser classificadas em diferentes categorias dependendo do mecanismo de aprendizagem e de como são treinados (supervisionados ou não) [49]. Uma vez treinada e aprendida a relação entre os inputs e o output pretendido, a rede neuronal artificial pode ser utilizada tanto para diagnóstico como prognóstico.

A topologia das Redes neuronais Artificiais depende da forma como os neurónios se conectam entre si para formar uma “rede” de neurónios. A topologia pode ser de redes diretas (*Feedforward*) ou de redes recorrentes (*Feedback*). Um exemplo de uma rede neuronal artificial *feedforward* ou Feedforward Neural Network (FFNN) está representada na Figura 2.8, onde cada círculo representa um nó ou neurónio e cada conjunto de nós na mesma coluna representa uma camada. Os nós na primeira e ultima camada representam respectivamente os parâmetros introduzidos (*inputs*) e o parâmetro final (*output*). O número de nós em cada camada intermediária ou oculta, deve ser determinada de modo a expressar adequadamente o mecanismo entre as camadas inicial e final, encaminhando os dados recebidos da primeira para a ultima.

O processo de treino ou aprendizagem equivale a determinar o peso ou importância dos parâmetros de modo a que a rede exprima com precisão a relação entre os inputs e output. Uma vez aprendidos, a rede pode então funcionar utilizando funções de transferência e parâmetros importantes. Algumas das funções de transferência disponíveis, são o *Sigmoid*, inversas e lineares, entre outras.

Os parâmetros de peso incluem peso e tendência. O peso, quadrados na Figura 2.8 são por norma multiplicados com o valor dos nós anteriores, e as tendências, representados por elipses, são adicionadas de forma a serem um input nas funções de transferência. Este processo de achar o peso óptimo dos parâmetros, é o chamado treino ou aprendizagem e requer vários blocos de dados.




Figura 2.8: Ilustração de uma rede neuronal artificial feedforward [40].

Já as redes neuronais artificiais recorrentes (*Feedback*) ou Recurrent Neural Network (RNN) (Figura 2.9) utilizam um conceito semelhante, apresentando como principal diferença a existencia de um feedback local entre as diferentes camadas [40].




Figura 2.9: Ilustração de uma rede neuronal artificial feedback [50].

Vários estudos têm demonstrado as vantagens destas redes, nomeadamente a sua velocidade [21, 51], conseguir um desempenho tão bom quanto métodos estatísticos tradicionais sem a necessidade de suposições quanto à distribuição [52] e a capacidade de identificar fenómenos complexos sem conhecimento *à priori* [8].

Algumas das principais características são a velocidade de processamento que se devem ao seu paralelismo, à sua habilidade de serem treinadas e em produzir respostas correctas e instantâneas a partir de dados incompletos e por isso leva a que seja esperado que tenham um bom desempenho na previsão de vida útil de sistemas complexos [34]. No entanto, não deixam de apresentar algumas limitações. Para além da pouca transparência já referida anteriormente, as redes neuronais artificiais requerem um grande número de dados de alta qualidade, que como também já foi discutido nesta dissertação, são difíceis de encontrar em ambiente industrial.

Os trabalhos de M. Elforjani [53], que utiliza uma RNA para relacionar os sinais acústicos emitidos com o correspondente desgaste dos rolamentos através de experimentos laboratoriais, e o trabalho de Zhigang Tian [54] que desenvolve um método de RNAs para prever com maior precisão o tempo de vida útil de equipamento sujeito a controlo de condição, utilizando dados de vibração recolhidos de rolamentos de bombas, são exemplos da aplicação de RNAs em técnicas de manutenção. Já Zemouri et al. [52, 55] tem desenvolvido o conhecimento nas RNN.

Outra das técnicas mais populares de machine learning é a lógica *fuzzy* [56]. Os sistemas de lógica *fuzzy* fornecem um idioma (com sintaxe e semântica própria) no qual se traduz conhecimento qualitativo sobre o problema a solucionar[57]. Em particular, a lógica *fuzzy* permite o uso de variáveis linguísticas para modelar sistemas dinâmicos. Estas

variáveis tomam/obtem valores *fuzzy* que são caracterizados por uma definição e uma função *membership*. O significado de uma variável difusa pode ser interpretada como uma restrição (elástica) ao seu valor. Estas restrições são propagadas como consequência do funcionamento *fuzzy*. O mecanismo de raciocínio resultante tem poderosas propriedades de interpolação, que tornam a lógica *fuzzy* bastante sólida, nomeadamente na variação de parâmetros do sistema, distúrbios, etc.

Quando aplicada em prognóstico, a lógica *fuzzy* é tipicamente utilizada em conjunto com outros metodos de machine learning, e é utilizada para lidar com incertezas de que todas as técnicas de prognóstico encontram. De facto, a gestão e representação das incertezas está no centro do desempenho e do sucesso nas técnicas de prognóstico. A previsão a longo termo de falhas implica uma maior incerteza que tem de ser lidada de forma eficiente. Por exemplo, quanto mais informação sobre a deterioração registada em componentes e sobre a sua previsão se tornam disponíveis, meios devem ser concebidos para reduzir os limites de incerteza [48].

Um dos exemplos em que a lógica *fuzzy* é utilizada em junção com outra técnica de machine learning são os sistemas Neuro-fuzzy (NF). Estes sistemas são sistemas de lógica *fuzzy* cuja estrutura é determinada ambos por especialistas e por funções *memberships* optimizadas, isto é, treinadas por RNAs [58].

Estes sistemas combinam os benefícios de 2 poderosos paradigmas, conhecimento especializado e da “inteligência” das RNAs, sendo por isso um dos mais promissores candidatos na previsão de tempo de vida útil de maquinaria. Permitem a capacidade de acomodar tanto os dados como o conhecimento especializado sobre o problema em questão [59]. No entanto, grande quantidade de dados de alta qualidade são também necessários.

Wang et al. [50] adoptou um sistema NF para desenvolver uma abordagem de prognóstico online para diferentes tipos de falhas de equipamentos. Hussain et al. [60] utilizou sistemas de dedução adaptável NF ou Adaptive neuro-fuzzy inference system (ANFIS), para prever os processos de degradação de caixas de velocidade de turbinas eólicas. Petkovic et al. [61, 62] utilizou também ANFIS na área de energia eólica.

Sistemas fuzzy são muito úteis em situações envolvendo sistemas muito complexos cujos comportamentos são de difícil interpretação e em situações onde uma solução rápida (mas aproximada) é necessária. Uma vantagem destes sistemas é que conhecimento especializado pode ser implementado para melhorar a aproximação por afinação, remoção ou adição de funções e regras de associação. A Figura 2.10 permite uma comparação visual entre uma abordagem clássica e uma abordagem fuzzy.




Figura 2.10: Comparação de uma abordagem clássica para fuzzy [57]

Outra das técnicas utilizadas que merecem destaque são as *Relevance/Support vector machines* (RVM/SVM) [63, 64].

Modelos híbridos

Como podemos constatar, todas as categorias apresentadas têm as suas limitações no que diz respeito à previsão de tempo de vida útil. Para superar essas limitações e tentando integrar as vantagens das abordagens anteriores, surgiram os modelos híbridos.

Os modelos híbridos não só permitem uma aprendizagem mais rápida em clusters distribuídos, como também permite a aplicações de machine learning uma maior eficiência quando dados e informações são demasiado grandes para serem armazenadas na memória de uma só máquina [49]. Algumas publicações [65, 66] utilizam diferentes métodos no desenvolvimento de um modelo de previsão de degradação combinando com algoritmo de *Particle filtering* (PF), outras combinam técnicas de *machine learning* com modelos de coeficientes aleatórios [67, 68].

Novas técnicas de modelos híbridos têm vindo a ser desenvolvidas, visto que juntam as vantagens de modelos baseado em Física e em dados, despertando o interesse da comunidade de investigação. No entanto, uma vez que combinam os métodos falados anteriormente, conhecimento especializado em ambas as áreas é necessário, o que leva a que o desenvolvimento de novas técnicas e aplicações seja ainda reduzido quando comparado com as anteriores.

2.3 Energia Eólica

Energias renováveis estão cada vez mais a desempenhar um papel importantíssimo na energia global, como alternativa a energias fósseis de modo a reduzir o impacto no ambiente e no aquecimento global.

É possível afirmar que a energia eólica surge a partir da energia solar, que é transmitida por radiação até à atmosfera terrestre. Esta radiação provoca um aquecimento superficial diferenciado das camadas de ar, originando variação da massa específica e gradientes de pressão. Pode então considerar-se a energia eólica um recurso renovável uma vez que a energia solar pode ser considerada infinita em relação ao tempo de vida humano [69, 70]. A Figura 2.11 ilustra a evolução do aproveitamento da energia eólica.




Figura 2.11: Evolução do aproveitamento da Energia Eólica.

A primeira grande máquina de vento a gerar eletricidade (cerca de 12kW) foi instalada em Cleveland, Ohio 1888. Pelo final da 1ª Guerra Mundial, o uso de máquinas de 25kW estava espalhada por toda a Dinamarca. Novos desenvolvimentos nos Estados Unidos inspirados pelas descobertas aeroespaciais, nomeadamente em hélices e asas de aviões, e outros esforços europeus, na Dinamarca, França, Alemanha e no Reino Unido (1935-1970) demonstraram que turbinas eólicas de grandes dimensões podiam funcionar. Podemos então afirmar que é algo que tem sido alvo de estudo e em constante evolução até aos dias de hoje, tendo como principal desafio no momento atingir 1000GW de produção de energia por 2030 [71].

No futuro a tendência é para a produção e instalação de grandes turbinas *offshore* (Figura 2.12), sendo que também a procura e a necessidade de energia eólica vai continuar a aumentar nos próximos anos e por isso é de esperar que o tamanho das turbinas eólicas e a sua capacidade venham a aumentar [72] (Figura 2.13).




Figura 2.12: Investimento (€ Milhões/ano) expectável em turbinas eólicas [73]




Figura 2.13: Crescimento e previsão das dimensões das turbinas [72]

2.3.1 Turbinas Eólicas

As Turbinas Eólicas são uma das fontes de produção de energia que mais tem crescido por todo o Mundo [74], como demonstra a Figura 2.14. As turbinas eólicas fornecem actualmente 4 % da eletricidade global. O custo da energia eólica caiu até 30 centavos/kWh na década de 1980, sendo que nos dias de hoje se situa nos 3 centavos/kWh [75]. Isto leva a uma necessidade constante de reduzir ao máximo os custos de operação e manutenção destas turbinas. Manutenção e reparação são actividades críticas que consomem tempo e esforço, sendo por isso dispendiosas.




Figura 2.14: Capacidade Total Instalada e prognóstico 1997-2020[MW] [74].

O relatório da Comissão Europeia de 2015 sobre o progresso das energias renováveis até 2020 mostra que, embora a UE esteja num bom caminho para atingir seus objetivos de energia renovável, os objetivos interinos tornar-se-ão mais desafiadores nos próximos anos e os Estados-Membros terão de intensificar os seus esforços para alcançar os objetivos de 2020 [76].

Para tornar a energia eólica mais competitiva em relação a outras fontes de energia, a fiabilidade e tempo de vida são cruciais, logo, um planeamento cuidado de manutenção baseado no estado do equipamento ajuda nesse sentido. Maioria das turbinas eólicas estão equipadas com algum tipo de aparelho ou sistema de controlo de condição, que fornece a informação sobre o equipamento para a base de dados (SCADA), sendo uma ferramenta normalmente utilizada para deteção precoce de falhas com vista a minimizar o tempo de paragem e maximizar a produtividade.

Como já referido anteriormente, a tendência para o futuro das turbinas eólicas é que estas aumentem em número e em dimensões, no entanto como se pode ver pela Figura 2.15, turbinas maiores têm tendência para falhar mais frequentemente e por isso mesmo, precisar de mais manutenção. Como tal, reduzir os custos de inspeção e manutenção torna-se cada vez mais importante [77].

Deste modo, sendo que falhas não expectáveis de componentes são uma realidade e porque tempo de paragem não previsto tem custos elevados, sistemas de controlo de condição são aplicados para melhorar o funcionamento das turbinas e reduzir os custos de operação.




Figura 2.15: Falhas em turbinas de diferentes dimensões [78].

2.3.2 Manutenção em Turbinas eólicas

Em situações onde defeitos podem ser detectados a olho nu, como a corrosão, fugas de óleo, descoloração das superfícies dos componentes que podem indicar ligeiras variações de temperaturas e deterioração, assim como o ruído dos rolamentos que pode indicar que algo está errado, já não precisamos de técnicas sofisticadas de monitorização, no entanto, o objectivo passa por evitar danos irreversíveis ou pelo menos detectá-los a tempo de poder agendar a próxima acção de manutenção de acordo com o melhor interesse para a produção.

No caso da maiorias das falhas mais comuns, como fissuras e rugosidade das pás, curto-circuitos no gerador, e sobreaquecimento da caixa de velocidades todas exigem uma abordagem mais sofisticada a nível de manutenção. Deste modo, surge uma alternativa em que se tenta mitigar a falha de componentes e a desagregação do sistema com manutenção baseada no controlo do condição, onde são empregues técnicas contínuas de supervisão e inspecção para detectar precocemente falhas e para determinar se serão necessárias quaisquer tarefas de manutenção antes destas. Isto envolve aquisição, processamento, análise e interpretação de dados e seleção de quais as acções de manutenção a tomar [77].

Numa turbina eólica, as principais falhas são por norma devidas à caixa de velocidades, gerador, rolamentos principais, pás, com as seguintes percentagens: 32%, 23%, 11% e inferior a 10% [59]. Os sistemas de controlo de condição são uma ferramenta que permite prever uma falha com base na informação fornecida pelo sistema do estado dos componentes.

SCADA são sistemas que, como o nome indica, recolhem dados e posteriormente os enca-minha para um computador central para revisão e avaliação. Regendo-se pela seguinte máxima “ Alterações significativas indicam início de falhas ”, os sistemas de controlo de condição são compostos por combinações de sensores e equipamentos de processamento de sinais que fornecem dados contínuos da condição dos componentes baseado em vari-adas técnicas, como análise de vibrações e ruído, análise de óleo, análises térmicas, etc. Nas turbinas eólicas elas são usadas para controlar o estado dos componentes principais tais como, as pás, a caixa de velocidades, gerador e rolamentos principais e torre.

Um sistema SCADA típico armazena dados de 10 em 10 minutos, dados esses que devem ser examinados de modo a perceber o estado da turbina e dos seus componentes. Os dados SCADA contêm informação sobre todos os aspectos de um parque eólico, desde a energia produzida e velocidade do vento como qualquer erro registado no sistema [79]. Os parâmetros tipicamente registados pelo SCADA de uma turbina eólica podem ser categorizados da seguintes maneira [59]:

1. Parâmetros de vento: como a velocidade e direcção.
2. Parâmetros de Funcionamento: como a energia produzida, velocidade do rotor e ângulo das pás.
3. Parâmetros de Vibração: como é que a vibração da torre afecta o nível de vibração (cargas dinâmicas) dos componentes no interior da nacelle [70].
4. Parâmetros de Temperatura: como a temperatura dos rolamentos e da caixa de velocidades.

Existe um vasto leque de estratégias de manutenção e suas aplicações no controlo de condição das turbinas, sendo estas as mais utilizadas até ao momento:

Análise de Vibrações - A análise de vibrações continua a ser a tecnologia mais popular utilizada nas turbinas eólicas, especialmente no equipamento sujeito a rotação. Diferen-tes sensores a diferentes frequências são utilizados: Transdutores são usados para baixas frequências, sensores de velocidade para frequência media e acelerómetros para altas frequências. Quanto às suas aplicações, é geralmente aplicado para supervisionar a caixa de velocidades, rolamentos e alguns outros componentes [80].

Ruído - A libertação rápida de energia resultante de deformação provoca a propaga-ção de ondas elásticas que podem ser analisadas. Esta técnica foi utilizada para detectar algumas falhas mais cedo do que outras técnicas, como por exemplo, através da análise de vibrações [77].

Análise do óleo - Quer para o propósito de garantir a qualidade do óleo ou o estado de vários componentes móveis, a análise do óleo é feita maioritariamente por amostragem apesar de sensores para controlo contínuo estarem disponíveis há anos. Pouca ou quase nenhuma vibração é perceptível no aparecimento de falhas, mas a análise do óleo consegue fornecer avisos prévios. Estas abordagens são eficientes e com o custo aceitável no que a evitar falhas graves diz respeito e tem vindo gradualmente a tornar-se mais importante com vários projectos em desenvolvimento [77].

Temperatura - A medição de temperatura ajuda a detectar a presença de potenciais falhas relacionadas com alterações de temperatura nos equipamentos. Na indústria de energia eólica, este método é aplicado sobre componentes como rolamentos, fluidos (óleo) e cablagem do gerador, entre outros. Este método de controlo de condição apesar de viável, sendo que cada peça de equipamento tem uma temperatura operacional limitada, raramente é utilizado sozinho já que a temperatura pode ser influenciada pelo ambiente e se desenvolve lentamente não sendo suficiente para a deteção precoce e precisa da falha [81].

No entanto, apesar da técnica utilizada, a eficiência de um sistema de controlo de condição recai sobre o número e tipo de sensores assim como os métodos de simplificação e processamento associados, utilizados para retirar a informação importante. Nomeadamente:

Métodos estatísticos - onde são aplicados algoritmos estatísticos para os propósitos de controlo de qualidade com vista a analisar os dados recolhidos pelos vários sensores na turbina eólica.

Reconhecimento de Padrões - refere-se à colheita de dados dos vários sensores e identificação de um padrão, algo que requer certos algoritmos e aplicações.

Seleção de dados - visto que por vezes numa grande quantidade de dados há informação que não tem nenhum relevo e que deve ser eliminada de modo a simplificar a programação.

A deteção e o diagnóstico de falhas podem também ser encarados como uma sofisticada adaptação de controlo de qualidade que incorpora algoritmos de inteligência artificial com o propósito de detectar com antecedência falhas e qual o seu grau de gravidade. Pré-processamento de SCADA é necessário para a extração de informações úteis e padrões de dados enormes. Os vários métodos de Inteligência Artificial utilizados para análise de dados SCADA de turbinas eólicas são: (RNAs), sistemas *fuzzy* e (ANFIS).

Alguns investigadores conseguiram demonstrar com sucesso o uso de algoritmos de Inteligência Artificial na análise de dados SCADA. Vários trabalhos têm sido realizados utilizando os dados de temperatura registados pelo sistema SCADA aplicando diferentes técnicas e algoritmos, relacionando a condição dos componentes com os parâmetros de temperaturas característicos, como redes neuronais artificiais (RNAs) [82], algoritmo de previsão de intervalos de confiança para valores de temperatura [83], entre outras.

Vendo o seu desempenho, acredita-se que a utilização de inteligência artificial pode melhorar a precisão dos modelos. É portanto, uma área que permanece aberta a mais investigação e que tem chamado a atenção de uma vasta comunidade científica.

2.3.3 Revisão Bibliográfica

Nesta secção falaremos sobre o estado da arte referente à manutenção em turbinas eólicas, dando mais ênfase a técnicas de inteligência artificial. Como vimos, o campo de manutenção tem sofrido vários avanços e desenvolvimentos ao longo dos últimos anos, acompanhada pela evolução da tecnologia, tendo por isso surgido varias técnicas envolvendo inteligência artificial.

Aliado ao facto da também crescente procura e investimento em fontes de energia renovável, nomeadamente turbinas eólicas, é com grande interesse e expectativa que se aguardam avanços na manutenção.

Métodos de Diagnóstico

Devido às duras condições de funcionamento e de cargas variáveis, as turbinas eólicas estão sujeitas a uma taxa relativamente alta de falha. Uma falha de um único componente de uma turbina eólica pode levar à falha desta levando a que deixe de trabalhar, aumentando assim o tempo de inactividade.

Um diagnóstico correcto numa fase inicial da falha resulta numa manutenção atempada e menor tempo de inactividade do sistema. Um procedimento de diagnóstico adequado deve ser não-intrusivo e capaz de fornecer uma indicação clara da falha incipiente.

A utilização do sistema SCADA para controlo de condição das turbinas eólicas é uma abordagem custo-eficiente para supervisão do estado da turbina. Vários trabalhos têm sido desenvolvidos com base nos dados recolhidos por este sistema, como diferentes métodos de detecção e diagnóstico de falhas.

K.Kim et al. [84] utilizaram uma série de dados para treinar redes neuronais artificiais e desenvolver algoritmos de detecção de anomalias e investigaram técnicas de classificação usando algoritmos de agrupamento (*clustering*) e análise de componentes principais

para capturar sinais de falhas. Registos atípicos devidos a uma falha na caixa de velocidades são identificados a partir de um conjunto de medidas originais, incluindo velocidades do rotor e potência produzida. Análises sistemáticas dos dados indicavam claras diferenças em situações de falha e de funcionamento normal entre diferentes parâmetros. Estas diferenças foram exploradas e utilizadas para o desenvolvimento de algoritmos de diagnóstico de falhas. Nestes algoritmos, análise de componentes principais (*PCA - Principal Components Analysis*) e técnicas de *clustering* não supervisionada como *SOFM - Self-organizing feature maps* são incorporados. Estas duas abordagens são bem sucedidas na produção de indicadores persistentes que são bem distinguidos dos gerados com base em dados correspondentes a funcionamento normal.

Mais recentemente, Phong B. Dao et al. [85] apresentou um novo método baseado na análise de co-integração de dados SCADA. Neste trabalho, a abordagem de co-integração é pela primeira vez utilizada com sucesso no controlo de condição em turbinas eólicas.

Um procedimento baseado na co-integração em duas etapas (*off-line e on-line*), representado na Figura 2.16 é realizado em seis parâmetros da turbina eólica (velocidade do vento, velocidade do rotor, potencia produzida, corrente do gerador e temperatura do rotor e caixa de velocidades), em que as tendências dos dados têm características não-lineares.

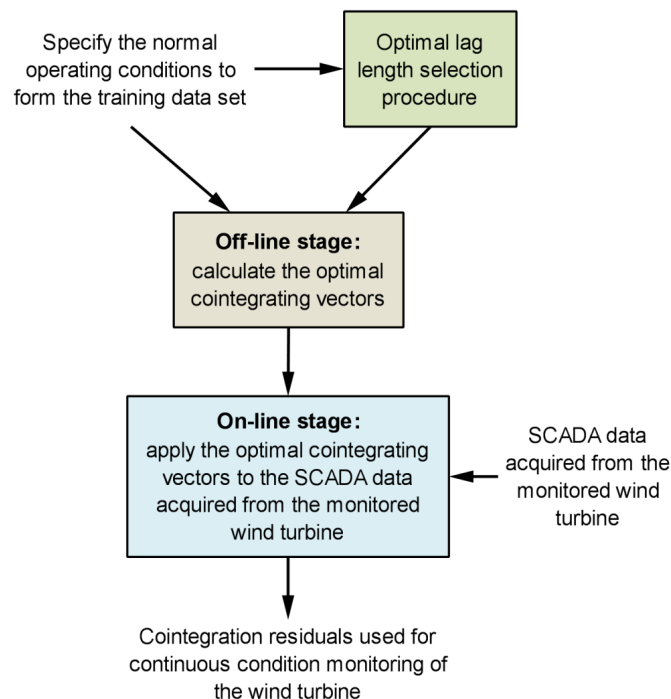


Figura 2.16: Diagrama do método co-integração aplicado [85].

O método apresentado por Phong B. Dao et al., que utilizou dados experimentais recolhidos de uma turbina eólica durante 30 dias, consegue interpretar automaticamente

e analisar grandes quantidades de dados SCADA e permite a transição de um processo de análise singular de parâmetros para uma interpretação e análise automáticas de um maior numero de parâmetros. Adicionalmente, a abordagem baseada em co-integração pode compensar os efeitos indesejáveis da variabilidade ambiental (velocidade do vento, temperatura exterior, etc.) e operacionais nos dados utilizados para controlo de condição e detecção de falhas de turbinas eólicas. Além disso, o método foi capaz de prever antecipadamente a ocorrência da falha de caixa de velocidades investigada e detectar esta falha no estágio inicial de sua ocorrência, o que, assim, pode melhorar a fiabilidade da turbina e reduzir os custos de manutenção, detectando falhas antes de atingir uma fase catastrófica.

Uma das vantagens deste método acaba por ser a sua simplicidade e o baixo custo computacional comparativamente a outras técnicas, como por exemplo, algoritmos de RNAs.

Himani et al. [86], propõe uma potencial abordagem baseada no uso da função *wavelet* para diagnóstico de falhas devido à excentricidade do rotor utilizando sinais eléctricos do gerador da turbina eólica. Dependendo da velocidade do vento, o gerador da turbina eólica opera continuamente em condições não estacionárias. Por norma, o desequilíbrio no sistema está relacionado com circunstâncias nas pás, como fadiga ou danos por impacto, água nas pás ou a superfície da pá estar coberta por camadas irregulares de gelo. Na frequência rotacional do veio, vibrações fortes serão introduzidas assim que o rotor estiver desequilibrado. Após passar pelo sistema de transmissão, esta excentricidade chegará por fim ao gerador.

Para o estudo apresentado neste artigo, uma instalação experimental foi desenvolvida e sujeita a variadas condições de vento e de carga utilizando uma carga resistiva variável trifásica em cada ramo do estator. Algoritmos da transformada rápida de Fourier (*FFT* - *Fast Forward Transform*) e transformada discreta de Wavelet (*DWT* - *Discrete Wavelet Transform*) foram aplicadas como técnicas de processamento de sinais. O espectro da condição saudável é utilizado como referência para o relacionamento com uma condição defeituosa.

O trabalho levado a cabo por Himani et al. [84] provou que a utilização de *FFT* restringe a habilidade em extrair instantaneamente a informação da frequência e amplitude de um sistema não-estacionário. Em comparação, *DWT* é capaz de interpretar instantaneamente a informação recolhida tirando proveito da suas bandas de frequência independentes e computações mais simples. Qualitativa e quantitativamente, *DWT* proporciona uma poderosa e eficiente ferramenta para interpretar os sinais não-estacionários de uma turbina com precisão. Foi possível também concluir que a amplitude da energia dos sinais da transformada de wavelet em componentes degradados é directamente proporcional à variação de velocidade e carga que pode ser uma base de indicador de falha para o controlo de condição de turbinas eólicas.

Falhas em turbinas podem ocorrer em vários componentes, como sensores ou partes de actuadores de parâmetros monitorizados. *Robust fault diagnosis* tem sido uma das preocupações. A incerteza de um sistema é praticamente inevitável e aumenta continuamente a probabilidade de ocorrência de falsos alarmes. Com base nessa preocupação, deve haver uma abordagem, na distinção entre falhas e perturbações para melhorar o desempenho global dos sistemas. A necessidade de desafiar a robustez do sistema é projetar um sistema de controlo de condição avançado e de diagnóstico de falhas para acompanhar com maior certeza o comportamento de uma turbina na presença de distúrbios.

A investigação por parte de S.Odofin et al. [87], utilizou um sistema dinâmico de energia de uma turbina eólica de 5MW, projectado para suportar controlo de condição e diagnóstico de falhas com o objetivo de melhorar a fiabilidade de sistemas de controlo práticos universais. Uma técnica estocástica híbrida é proposta com base num observador aumentado combinado com a atribuição de *eigenstructure* para a parametrização e optimização do algoritmo genético (GA) para tratar e atenuar a incerteza gerada principalmente por distúrbios.

Diferentes cenários são empregados para explorar falhas de sensores e actuadores que têm impactos directos e indirectos em sistemas modernos de turbinas eólicas, com base em componentes de controlo de condição que são propensos a mau funcionamento, com o objectivo de determinar o efeito das falhas simuladas relacionadas com a incerteza em relação a distúrbios ambientais comuns em ambientes operacionais reais. O método desenvolvido contribui com mais informações em relação a atenuação de distúrbios de sistemas estocásticos lineares que também podem ser aplicados diretamente a sistemas não-lineares e demonstrou um bom desempenho na análise de falhas previamente “alarmadas” com a presença de incerteza.

P.Cross [88] apresentou um método com um modelo não-linear baseado em dados na qual os parâmetros do modelo variam como funções de variáveis do sistema. Modelos obtidos a partir de dados SCADA foram utilizado para identificar falhas na caixa de velocidades e no gerador. Limites obtidos a partir da previsão do modelo, formam a base do sistema capaz de providenciar um aviso prévio da falha do componente.

Vários artigos de revisão de técnicas de diagnóstico desenvolvidas nos últimos anos podem ser encontradas, tais como *SCADA data based condition monitoring of wind turbines* de Wang et al. [59] e *A review of wind turbine bearing condition monitoring: State of the art and challenges* de H. de Azevedo et al. [89].

Métodos de Prognóstico

É estimado que se possa poupar cerca de 150.000 dólares por cada substituição da caixa de velocidades por turbina utilizando técnicas de prognóstico a longo termo, o que leva a um retorno substancial do investimento inicial. No entanto, técnicas de prognóstico a longo termo requerem uma precisa determinação das cargas em todos os 6 graus de liberdade do sistema.

Alvarez et al. [90] desenvolveu um novo método de prognóstico baseado em física, utilizando o binário, que pode ser estimado a partir dos dados recolhidos pelo sistema SCADA (velocidade do rotor e potência). Tendo em conta que os dados SCADA são recolhidos em intervalos de 10 minutos, que resulta numa menor precisão, o método apresentado introduz uma abordagem mais precisa para o cálculo de histogramas de binário baseado em dados SCADA. Usando distribuições de 10 minutos de potência e velocidade do rotor, este método é capaz de reconstruir com sucesso a distribuição de binário instantâneo entre os intervalos de 10 minutos registados pelo SCADA. O método prevê uma região de binário elevado mais disperso que o método actual utilizado na indústria, que introduz resultados substancialmente diferentes quando usados em prognóstico. Usando este método numa turbina eólica GE 1.5 SLE, é demonstrado que o erro é reduzido em 10.1%. Na Figura 2.17 é possível ver a comparação entre o método utilizado na indústria (Método1) e o apresentado (Método2).




Figura 2.17: Resultado do estudo [90].

Outra técnica de prognóstico baseado em conhecimento físico foi apresentada por Zhu et al. [91], que apresentou uma solução para o controlo de condição e previsão de

RUL on-line do óleo de lubrificação utilizando sensores DC (*dielectric constant*) e de viscosidade juntamente com uma técnica de filtro de partículas.

Já numa abordagem estatística para prognóstico do estado de um componente, a estatística Bayesiana tem chamado à atenção [92, 93].

O método proposto por J.Herp et al. [92] demonstrou com sucesso a capacidade de prever, em média 33 dias antes, uma falha em rolamentos. Uma previsão do estado da turbina foi apresentado, baseando-se na influência da temperatura do rolamento e processos Gaussianos. Utilizando dados de eventos das turbinas eólicas, mostrou-se que a previsão de um evento de falha selecionado, no caso *Bearing Over-temperature*, é possível.

Z.Song et al. [93] apresenta uma estrutura Bayesiana para identificar estados invulgares de turbinas eólicas baseado em dados SCADA. Neste trabalho 3 diferentes métodos, método BIN, distribuição normal de multivariáveis e método *Copula* foram utilizados para identificar esses diferentes estados da turbina. Os seus desempenhos foram comparados, tendo o método de *Copula* sobressaído, providenciando uma identificação mais promissora de estados do componente após determinar a combinação adequada de funções de distribuição acumulativa (CDF) e formas do modelo *Copula*. Comparativamente ao método de controlo de condição baseado na curva de potência o método proposto demonstrou um melhor desempenho.

Quanto a técnicas de prognóstico utilizando inteligência artificial, Z.Tian et al. [94] propôs uma política de manutenção definida por 2 limiares de probabilidade de falha ao nível da turbina eólica. Baseado na informação recolhida através do controlo de condição e prognóstico, os valores de probabilidade da falha no componente e na turbina podem ser calculados, permitindo que as decisões ótimas de CBM sejam tomadas. O método é composto essencialmente por 4 etapas (Figura 2.18), sendo inicialmente criado o modelo RNA para de seguida iniciar a simulação, depois dá-se o cálculo da condição do componente e de probabilidade de falha e por fim a decisão de CBM otimizada.

Kusiak [95] optimizou 5 algoritmos de RNAs para identificar uma relação entre os parâmetros definidos e a temperatura do rolamento do gerador durante condições de funcionamento normais. O trabalho desenvolvido permitiu prever valores de temperatura acima do recomendado 1.5h antes.

P.Bangalore [96] desenvolveu uma rede neuronal capaz de se auto-evoluir para prognóstico de falhas em turbinas eólicas utilizando dados SCADA. A abordagem ajuda a decidir um novo conjunto de dados de aprendizagem quando certas condições, como atividades de manutenção planeadas e não planeadas, são realizadas. Este tipo de actualização contínua manterá o modelo em sintonia com as condições de operação da turbina e tornar a previsão de falhas precisa e confiável. Esta abordagem reduz a intervenção

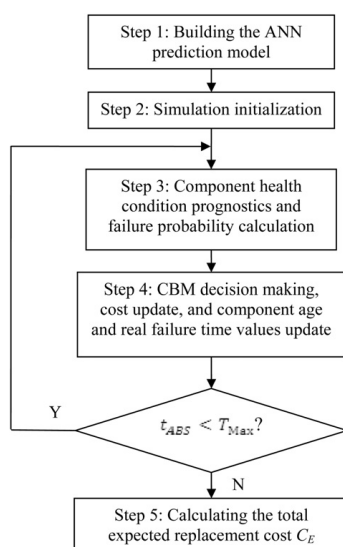


Figura 2.18: Esquema do método de simulação [94].

humana, tornando-a mais independente e intuitiva.

Mais tarde, e na sequência do estudo anterior, P.Bangalore et al. [97] apresenta uma estrutura de gestão de manutenção chamada *SEMS (Self Evolving Maintenance Scheduler)* que providencia guias para utilização de dados adquiridos de diversas fontes com o objectivo de otimizar a política de manutenção. A aplicação de uma RNA baseada em controlo de condição é apresentada para uma turbina eólica com uma falha na caixa de velocidades, onde o sistema foi capaz de detectar a falha com 2 meses de antecipação. Uma optimização de um modelo matemático para manutenção planeada chamada *Preventive Maintenance Scheduling Problem with Interval Costs (PMSPIC)* é apresentada com alterações para otimizar a manutenção tendo em consideração a idade e a condição do componente. A aplicação do modelo a um caso de estudo permitiu concluir que o modelo apresentado pode disponibilizar planeamentos de manutenção mais flexíveis quando comparado com a manutenção preventiva sistemática.

S.Hussain [60] propôs uma técnica que permite obter um índice de estado do componente, no caso, uma caixa de velocidades, utilizando dados de vibração. Este índice é calculado utilizando duas técnicas de previsão, *ANFIS* e modelo não-linear auto-regressivo (*NARX - nonlinear autoregressive model with exogenous inputs*).

B.Chen [98] propôs um novo procedimento para prognóstico de falhas no *pitch* de uma turbina eólica utilizando *ANFIS* baseadas no conhecimento *a-priori (a-priori knowledge-based)*. Com a vantagem da incorporação do conhecimento *a-priori*, o sistema proposto melhora a capacidade de interpretação de condições anteriormente despercebidas e assim melhora o diagnóstico de falhas. O método foi testado com sucesso num parque eólico composto por 26 turbinas, revelando uma capacidade de prever falhas no *pitch* até 21

dias antes.

Y.Sinha et al. [99] propõe esquema de prognóstico de falhas e um modelo de base de dados de uma ferramenta de software para uma eficaz manutenção de turbinas eólicas. Técnicas como RNAs e Redes Bayesianas são utilizadas.

M.Djeziri et al [100] apresenta um método híbrido para previsão de *RUL*. O método utiliza um modelo físico de uma turbina eólica, validado sob condições de operação reais para simular condições de funcionamento normal e de funcionamento com falhas mais recorrentes, com o objectivo de criar uma base de dados completa, que será utilizada para *clustering*. O agrupamento em *clusters* é então realizado em 3 passos. O primeiro é a projecção dos dados no espaço residual calculado através da análise de componentes principais (PCA) de situações de funcionamento normal. No segundo passo, todos os dados são projectos no espaço residual, dando origem a *clusters* facilmente distinguíveis entre si, representando as situações de funcionamento normal e de falhas. Por fim e como ultimo passo, *RUL* é calculada utilizando uma abordagem cinemática baseada no cálculo da distância euclidiana de situações de funcionamento normal para clusters de funcionamento defeituoso. O cálculo da velocidade de degradação permite calcular a *RUL* como uma relação entre a posição euclidiana e a velocidade de degradação.

P.Mazidi et al [101] propõe uma técnica de prognóstico utilizando RNAs e modelos de risco proporcionais (*PHM - Proportional Hazardous model*) em dados recolhidos pelo sistema SCADA. O objectivo do método proposto são de disponibilizar um modelo de condição baseado na tensão. Seis diferentes técnicas são aplicadas com objectivo de ordenar as variáveis introduzidas com base na sua importância. De seguida, um modelo de comportamento normal é criado baseado em RNAs. Posteriormente, um valor do desvio é obtido a partir dos resultados do modelo RNA que contém informações de condição da turbina eólica. Então, um modelo de condição de tensão baseado em *PHM* é desenvolvido. Uma combinação dos resultados dos dois modelos oferece a possibilidade de avaliar as políticas de manutenção adoptadas e oferece recomendações para melhorar as estratégias de manutenção.

Uma abordagem de filtragem de partículas (*particle-filtering modeling*) foi também apresentada por X.fan et al [102] para previsão de *RUL* da caixa de velocidades de uma turbina eólica baseado em dados recolhidos pelo sistema SCADA.

Para simplificar a análise de dados das pás de turbinas eólicas e melhorar a eficiência do seu controlo de condição, um novo método transformando os sinais do momento das pás num eixo horizontal é apresentado por J.Lee et al [103]. Ao invés de processar os sinais do momento das 3 pás directamente, o algoritmo proposto transforma os 3 sinais sinusoidais em 2 sinais estáticos relativamente ao centro de rotação das pás através de

síntese vectorial e transformação de coordenadas, e elimina também os componentes de frequência devido à rotação da pá do sinal obtido. Adicionalmente, o algoritmo considera o ponto de vista de um observador no exterior das pás e, como resultado, reduz significativamente o efeito da frequência rotacional da pá, de modo a assegurar uma supervisão mais precisa das pás.

R.Carrato [104] propõe um método para avisos e detecção de falhas utilizando técnicas de *clustering* e distância de Mahalanobis. Ambas as técnicas são desenvolvidos num ambiente real de um parque eólico para componentes críticos da turbina eólica. Um curva de potencia é modelada a partir de técnicas de agrupamento seguindo lógica *fuzzy* (*clustering*) e técnicas de *parametric fitting* num primeiro momento. De seguida, avisos e alertas registados pelo sistema SCADA são analisados e verificadas as suas localizações e distâncias da curva. A técnica de Mahalanobis é escolhida para esse propósito e a sua precisão é validada comparando-a a outros métodos considerados. Comportamentos invulgares são facilmente detectáveis a baixa e altas velocidades e potências do vento, no entanto, para zonas de velocidades médias do vento e potência, ou seja a zona funcional mais comum, torna-se mais difícil.

A distância de Mahalanobis é uma medida de distância que leva em conta o facto de que a variância em cada direcção pode ser diferente e a covariância entre variáveis. Esta distância pode ser comparada com a distância euclidiana pesando a covariância dos dados. Pode-mos dizer que é como se o espaço euclidiano fosse rodado com base na matriz de covariância dos dados.

A Figura 2.19 demonstra a distância de Mahalanobis dos valores de potência e velocidade do vento de todos os clusters utilizados neste estudo.




Figura 2.19: Distância de Mahalanobis [104].

Vantagens como a fácil integração em sistemas SCADA e a sua capacidade para detectar falhas em tempo real, como a possibilidade de estender o método para análise estrutural dos elementos da turbina, tornam o método aliciante.

Outros trabalhos revelando os mais recentes métodos aplicados a controlo de condição de turbinas[105] bem como técnicas de prognóstico aplicadas [106] têm sido publicados.

Caso de Estudo

Pelo decorrer da dissertação, pudemos depreender que várias técnicas de controlo de condição têm sido aplicadas a turbinas eólicas. No entanto, estas técnicas são tipicamente focadas na análise de vibrações, fazendo com que a avaliação de deterioração precoce seja difícil, devido ao elevado volume de dados habitualmente disponíveis e à variabilidade das cargas dinâmicas a que a estrutura está sujeita. Além disso, os dados de vibração não são normalmente disponibilizados ou armazenados pelo sistema SCADA a que os proprietários dos parques eólicos têm acesso e por norma requerem sensores ou equipamentos adicionais, que aumentam diretamente os custos.

No entanto o trabalho onde nos iremos focar e desenvolver fornece um método de avaliação da probabilidade de condição da deterioração precoce para componentes críticos baseado apenas em parâmetros de funcionamento como a temperatura e a velocidade de rotação [107].

Um aumento inesperado na temperatura dos componentes pode indicar sobrecarga, má lubrificação ou, possivelmente, arrefecimento passivo ou activo ineficaz, por exemplo, quando um sistema de arrefecimento se torna parcialmente bloqueado ou defeituoso por algum motivo. Possuindo características de inércia térmica e forte capacidade anti-interferência, a temperatura pode ser usada para indicar uma deterioração crítica dos componentes.

Além disso, grandes quantidades de dados de temperatura são facilmente adquiridas pelo sistema SCADA. Portanto, este sistema pode ser uma maneira viável para estabelecer um grau de deterioração, analisando a relação entre grau de deterioração e parâmetros característicos de temperatura dos componentes críticos.

A Figura 3.1 ilustra o modo como os sensores de temperatura estão distribuídos pelos componentes de uma turbina eólica, nomeadamente pelos componentes estudados:

1. *No.1 main bearing temperature.*
2. *Gearbox front bearing temperature.*
3. *Gearbox oil temperature.*




Figura 3.1: Sensores de temperatura [81].

O trabalho levado a cabo por Y. Hu et al [107] propõe, em primeiro lugar um limiar dinâmico para a função de grau de deterioração baseado em dados SCADA de parâmetros característicos de temperatura e velocidade do rotor. Em segundo lugar, é apresentado um método de avaliação de probabilidade de deterioração precoce, combinando os conceitos de grau de deterioração, limiares dinâmicos e método de estimação não paramétrico.

Esta dissertação pretende dar seguimento a estes métodos, analisando-os e fazendo as alterações necessárias de modo a aplicar a diferentes casos de estudo, nomeadamente a dados SCADA de parques eólicos portugueses contribuindo para melhoria da qualidade das acções de manutenção.

Para o desenvolvimento e aplicação do algoritmo foi utilizado o software computacional MATLAB.

3.1 Descrição do Método em Estudo

Inicialmente o conceito de grau de deterioração tem de ser introduzido com vista a distinguir o nível de deterioração entre situações de funcionamento ideal e de possíveis falhas. O grau de deterioração é definido no intervalo $[0, \infty]$, onde um valor mais pequeno geralmente se traduz num melhor estado do componente. O grau de deterioração pode ser dado por:

$$g(x) = \frac{x - \beta_1}{\beta_2 - \beta_1} \quad (3.1)$$

onde g é o grau de deterioração, β_1 e β_2 limites inferiores e superiores respectivamente, e x a temperatura registada.

A tendência do grau de deterioração é para subir com o tempo de operação, visto que a tendência da temperatura dos componentes é também para aumentar. No entanto alterações nos valores de temperaturas registadas reflectem uma grande afinidade com velocidades do rotor diferentes. Deste modo, os limites superior e inferior têm um papel crucial para a obtenção do grau de deterioração real e na análise da alteração da condição dos componentes. É então necessário que ambos os limites superior e inferior sejam também eles variáveis.

Limite superior variável - Devido à afinidade entre a velocidade do rotor e a temperatura, uma função relacionando as 2 é estabelecida extraíndo os dados de falha do sistema SCADA através do método de ajuste de dados para adquirir o limite superior de temperatura sob velocidade variável do rotor.

Limite inferior variável - O valor de temperatura do componente em bom estado é mais pequeno que o componente deteriorado à mesma velocidade do rotor. Logo, todas as turbinas de um parque eólico podem ser classificadas em grupos diferentes seguindo um método de classificação por agrupamentos de acordo com o princípio de velocidade do rotor aproximadamente igual. Além de que o valor mínimo das mesmas características de temperatura num mesmo grupo pode ser determinado como um limiar inferior dinâmico.

O estado de deterioração é dividido em quatro categorias [l_1 – *Excelente*, l_2 – *Bom*, l_3 – *Alerta*, l_4 – *Perigo*], relacionando-se do seguinte modo com o grau de deterioração: $l_1 \in [0, 0.30]$, $l_2 \in [0.30, 0.55]$, $l_3 \in [0.55, 0.80]$, $l_4 \in [0.80, \infty]$. A Figura 3.2 demonstra a distribuição do grau de deterioração por estas 4 categorias.

Para o desenvolvimento deste algoritmo e consequentemente desta dissertação, eram necessários o livro de eventos de manutenção e avarias, bem como os dados de temperatura e velocidade do rotor da turbina. Felizmente, uma empresa responsável por parques eólicos portugueses disponibilizou-se para o fornecimento destas informações, pelo qual demonstro a minha gratidão.




Figura 3.2: Exemplo de caso de estudo [107].

3.2 Descrição do Parque e Turbinas

O parque eólico em estudo, situado no noroeste de Portugal Continental e operacional desde 2006, conta com uma potência instalada de 18.4 MW repartida por 8 turbinas eólicas Nordex N90/2300. As características técnicas do parque podem ser vistas na Tabela 3.1.

Tabela 3.1: Características Técnicas do Parque

Parque Eólico em estudo	
Potência Instalada	18 MW
N.º de Turbinas Eólicas	8
Tensão de Ligação à Rede	60 kV
Emissões de CO2 Evitadas	22.662 ton
Produção Anual Estimada	40GWh

As turbinas Nordex N90/2300, pelas quais o parque é composto e foram alvo de estudo, são produzidas pela empresa dinamarquesa Nordex. Estas turbinas usufruem de um sistema de controlo autónomo controlado via PLC (Controlador Lógico Programável) que processa os dados provenientes dos diversos sensores.

O rotor consiste em 3 pás feitas de poliéster com fibra de vidro fortalecido, o cubo, os rolamentos e correias do sistema "*pitch control*".


A caixa de velocidades é uma caixa de velocidades planetária de duas velocidades, com uma engrenagem giratória de uma etapa. O gerador é uma máquina assíncrona de alimentação dupla.

A caixa de velocidades e o gerador têm sistemas de arrefecimento independentes. A primeira dispõe de um sistema de arrefecimento de um circuito óleo-agua-ar com diferentes estágios de arrefecimento, enquanto os rolamentos e engrenagens são lubrificados continuamente por óleo arrefecido. Já o sistema de arrefecimento do gerador é baseado num circuito de água, que assegura condições de operação óptimas em diferentes tipos de clima [108].


De modo a apresentar as características técnicas da turbina foi construída a Tabela 3.2, como também as suas dimensões e curva de potência podem ser vistas na Figura 3.3.

Tabela 3.2: Características Técnicas das Turbinas

Características Técnicas das Turbinas	
Fabricantes	NORDEX
Modelo	N90 - R80
Potência da Turbina Eólica	2.300 kW
Altura da Torre	80 m
Diâmetro do Rotor	90 m
Velocidade de Rotação da Turbina	9.6-16.9 rpm



(Medidas)



(Curva de potência)

Figura 3.3: Características da Turbina Eólica Nordex N90/2300.

3.3 Análise Preliminar dos dados

Foram então disponibilizados dois ficheiros Excel pela empresa responsável pelo parque eólico. Um contém o registo de eventos de manutenção em todas as turbinas, enquanto o outro, dados adquiridos pelos sensores instalados nas turbinas eólicas, durante um período de 3 anos (2011, 2012, 2013).

Os sensores estão ligados ao Sistema Central de Aquisição de Dados (SCADA), que regista a informação recolhida a cada 10 minutos. É então obtida uma tabela de grandes dimensões, onde cada linha representa uma turbina e cada coluna uma variável. Para este trabalho serão usados os dados registados referentes à velocidade do rotor e das temperaturas registadas nos rolamentos principais e na caixa de velocidades maioritariamente.

O primeiro passo consiste em converter este ficheiro para um de menor dimensões com vista a reduzir o esforço necessário por parte da máquina para o tratamento de dados. Deste modo, os dados foram convertidos para matrizes em MATLAB, cada uma com os registos anuais.

De seguida, repartimos os dados por matrizes que dizem respeito a uma só variável. Isto é, temos tantas matrizes quanto o número de variáveis das quais foram registados dados recolhidos pelos sensores. Uma vez que para aplicação do nosso algoritmo são apenas necessários os valores de temperatura de componentes da turbina eólica e de velocidade do rotor, a primeira filtragem de dados é então realizada. Assim sendo, ficamos reduzidos a 3 matrizes/ano:

◇ Velocidade do Rotor.

◇ Temperatura do Rolamento da Caixa de Velocidades.

◇ Temperatura do Rolamento Principal.

Cada matriz destas é composta por R linhas (equivalente ao número de registos anuais) e por 8 colunas (correspondentes às turbinas do parque). A seguinte matriz exemplifica o modo como os dados estão organizados.

$$Matriz_{VT} = \begin{bmatrix} a_1 & a_2 & a_3 & a_4 & a_5 & a_6 & a_7 & a_8 \\ b_1 & b_2 & b_3 & b_4 & b_5 & b_6 & b_7 & b_8 \\ c_1 & c_2 & c_3 & c_4 & c_5 & c_6 & c_7 & c_8 \\ d_1 & d_2 & d_3 & d_4 & d_5 & d_6 & d_7 & d_8 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ R_1 & R_2 & R_3 & R_4 & R_5 & R_6 & R_7 & R_8 \end{bmatrix}$$

Como já mencionado ao longo desta dissertação, nomeadamente no Capítulo 2, tanto os dados de eventos como os dados de controlo de condição apresentam semelhante importância no que diz respeito à colheita de informação para propósito de identificação de falhas, diagnóstico e prognóstico. O próximo passo, que permite a continuação e desenvolvimento do algoritmo, passa pelo cruzamento de dados destas duas informações.

O objectivo principal deste algoritmo é determinar um grau de deterioração dos componentes de uma turbina eólica. Para isso, uma vez que temos acesso a dados reais em ambiente operacional, partimos para a identificação de acções de manutenção registadas no *log* de eventos, sem a qual seria impossível realizar o presente estudo. Encontramo-nos então, na etapa de identificação de falha.

Analisando o ficheiro Excel com os dados de eventos, podemos identificar os dias e qual o tipo, isto é, a localizar ou isolar (caixa de velocidades, rolamento principal, *etc.*) o tipo de falha e em qual das 8 turbinas aconteceu.

Uma vez identificados os dias de avarias ou de intervenção, é necessário encontrar os registos correspondentes. Sabendo que o sistema SCADA regista dados a cada 10 minutos e que começam a ser registados no início de cada ano, é possível encontrar o número de registos até à data seguindo a equação:

$$R = 6 * 24 * D \quad (3.2)$$

onde R diz respeito ao número de registos 6 corresponde aos dados SCADA registados por hora, 24 às horas diárias e D ao número de dias até à ocorrência do evento.

Este cruzamento de informações e triagem de dados permite uma vez mais reduzir a dimensão das matrizes para um número de linhas igual a R registos, como também qual a matriz (dependendo da localização da falha) em estudo.

Por fim teremos então duas matrizes finais prontas à aplicação e desenvolvimento do algoritmo. Uma sempre correspondente à *Velocidade* de rotação do rotor e a outra à

Temperatura do componente onde foi identificada a falha.

Sabendo em qual das 8 turbinas foi necessária intervenção e sabendo também as características técnicas da turbina NORDEX N90/2300, mais especificamente o intervalo de velocidade de rotação da turbina, isto é, os valores para os quais a turbina está efetivamente em funcionamento, vai de 9.6 *rpm* a 16.9 *rpm*, temos de restringir as nossas matrizes para valores de acordo com este intervalo.

Começando pela matriz de *Velocidade do Rotor*, são excluídos todos os registos (linhas da matriz) cujos valores de velocidade de rotação das turbinas se encontrem fora do intervalo. De seguida, a matriz de *Temperatura* do componente em causa é também reduzida para os valores de temperatura correspondentes aos valores de velocidade do rotor aceites.

Ficamos então com duas matrizes, com o mesmo número de linhas, com os valores de velocidade do rotor entre 9.6 e 16.9 *rpm* e as temperaturas correspondentes.

3.4 Desenvolvimento e aplicação do Algoritmo

3.4.1 Desenvolvimento

Uma vez concluído o tratamentos de dados, podemos iniciar a elaboração do algoritmo. Recordando a equação 3.1, comecemos por desenvolver a parte do algoritmo que nos permite identificar o limite inferior variável β_1 , de seguida o limite superior variável β_2 que por fim nos permitirá encontrar um grau de deterioração g .

3.4.1.1 Limite Inferior Variável, β_1

Comparativamente à velocidade do vento, a velocidade do rotor é capaz de reflectir com mais eficiência as condições operacionais de uma turbina eólica.

A ideia para encontrar um limite inferior variável passa por dividir todas as turbinas em diferentes grupos com velocidades do rotor idênticas, no mesmo instante de tempo, sendo que o valor mínimo de temperaturas correspondentes de cada grupo pode ser visto como o limite inferior variável.

Para garantir que todas as turbinas estão a funcionar ao mesmo nível operacional, é então necessário assegurar que a diferença entre máximo e mínimo da velocidade do rotor cada grupo não excede o valor de 1 *rpm*, como exemplifica a equação 3.3 :

$$\Delta_n = n_{\max(t)} - n_{\min(t)} < 1 \quad rpm \quad (3.3)$$

em que $n_{\max(t)}$ e $n_{\min(t)}$ são os valores máximos e mínimos de velocidade do rotor no instante de tempo t .

Os grupos por onde são divididas as turbinas são criados por uma técnica de clustering utilizando a lógica fuzzy, nomeadamente o algoritmo *fuzzy C-means*. A matriz *Velocidade do Rotor* é normalizada antes da aplicação do algoritmo.

Fuzzy C-means é um método de agrupamento (*clustering*) que permite a um valor pertencer a 2 ou mais clusters. Este método foi desenvolvido por Dunn em 1973 [109] e melhorado por Bezdek em 1981 [110] e é utilizado para reconhecimento de padrões. Baseia-se na minimização da seguinte função:

$$J_m = \sum_{i=1}^D \sum_{j=1}^N u_{ij}^m \|x_i - c_j\|^2, \quad 1 \leq m < \infty \quad (3.4)$$

onde, D é o número de dados, N é o número de clusters, m é o expoente da matriz de partição para controlar o grau de sobreposição fuzzy, x_i é o i -ésimo ponto dos dados, c_j é o centro do cluster j e u_{ij} é o grau de adesão x_i no cluster j .

Fuzzy C-means realiza os seguintes passos para o clustering:

1. Inicia com valores aleatórios de membership referentes aos clusters.
2. Calcula o centro dos clusters:

$$c_j = \frac{\sum_{i=1}^D u_{ij}^m x_i}{\sum_{i=1}^D u_{ij}^m} \quad (3.5)$$

3. Actualização de u_{ij} de acordo com:

$$u_{ij} = \frac{1}{\sum_{k=1}^N} \quad (3.6)$$

4. Calculo da função inicial J_m .

5. Repetição dos passos 2 a 4 até J_m melhorar pelo menos até um limiar mínimo especificado ou até atingir um número máximo de iterações definidas.

O resultado final da aplicação deste algoritmo é uma matriz composta por tantas linhas quanto o número de clusters e tantas colunas quanto o número de dados utilizados, com valores pertencentes ao intervalo $[0, 1]$ representando a *membership* relativamente ao cluster. A seguinte matriz, onde são apenas utilizados 2 clusters (2 linhas) surge como exemplo.

$$Matriz_{exemplo} = \begin{bmatrix} 0.4 & 0.72 & 0.55 & 0.3 & 0.9 & 0.6 & 0.6 & 0.34 \\ 0.6 & 0.28 & 0.45 & 0.7 & 0.1 & 0.4 & 0.4 & 0.66 \end{bmatrix}$$

A Figura 3.4 permite ter uma percepção visual do método explicado, onde as diferentes cores correspondem ao número de clusters (2), os círculos representam valores pontuais do bloco de dados e a cruz(X) o centro dos clusters.




Figura 3.4: Representação gráfica do resultado do algoritmo Fuzzy C-means (2 clusters).

Após o agrupamento realizado pelo algoritmo, ficamos então com as turbinas e as suas respectivas *velocidades do rotor* no instante t divididas pelos diferentes clusters.

No algoritmo desenvolvido foi definido um *número mínimo de clusters* $N = 2$ e um *número máximo* de $N = 8$, para casos extremos onde teríamos apenas uma turbina por cluster.

Resta agora confirmar a condição imposta em 3.3 ($\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$) em cada cluster. No algoritmo desenvolvido foi definido um número mínimo de clusters $N = 2$ até um máximo de $N = 8$, para casos extremos onde teríamos apenas uma turbina por cluster. O processo será repetido tantas vezes quanto necessário até que cada cluster respeite a condição, com $N = N + 1$.

Uma vez verificada a condição obtemos por fim os clusters com as turbinas distribuídas com velocidades do rotor semelhantes e os seus respectivos valores de temperatura. O último passo envolve a identificação do cluster onde se encontra a turbina que sofreu a falha. Após identificado o cluster, é retirado o valor mínimo de temperatura. Esse valor, corresponde ao *Limite Inferior Variável*, β_1 .

Um diagrama apresentando todos os passos necessários até obter o β_1 é apresentado na Figura 3.5.

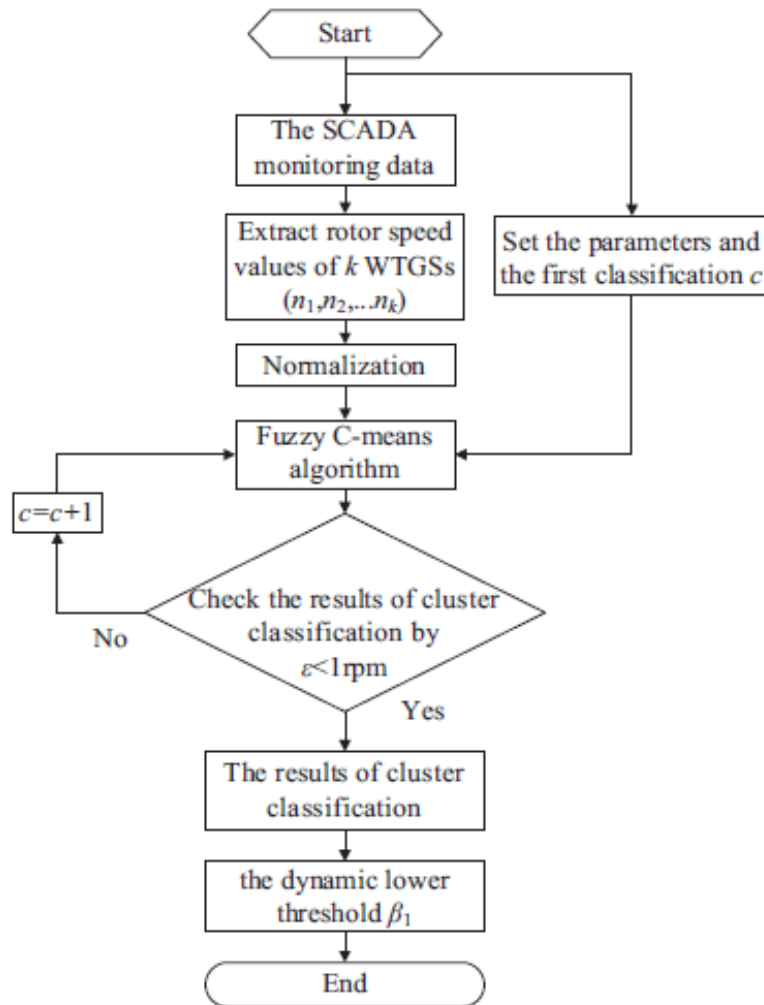


Figura 3.5: Diagrama do cálculo de β_1 onde c corresponde ao número de clusters [107].

3.4.1.2 Limite Superior Variável, β_2

A temperatura de um componente degradado é maior que a temperatura do mesmo em estado normal. Uma vez que os parametros de temperatura são porporcionais à velocidade do rotor, a falha pode ser analisada com um método BIN [111].

Para encontrar o limite superior variável começamos por dividir os valores de *Velocidade do Rotor* da turbina em que se deu a falha, por d bins desde o valor mínimo de velocidade até ao valor máximo. O número de bins d é dado por:

$$d = \frac{n_{max} - n_{min}}{0.5} \quad (3.7)$$

sendo que n_{max} e n_{min} correspondem aos valores máximo e mínimo de velocidade do rotor respectivamente.

Para distribuição dos valores pelas bins determinados anteriormente é utilizada a função histcounts do MATLAB. Esta função é utilizada da seguinte forma $[R, edges, bin] = histcounts(Velocidade do Rotor, d)$ onde d é o número de bins determinado previamente. Esta função devolve um vector $[bin]$ com os índices referentes a qual bin os diferentes valores de velocidade do rotor pertencem.

A distribuição é feita de acordo com a função, resultando no final numa matriz com 3 colunas, onde a *primeira* coluna revela a qual bin pertence o registo, a *segunda* qual o valor de *velocidade do rotor* e a *terceira* qual o valor de *temperatura* correspondente. Um exemplo é dado na Tabela 3.3 para facilitar a compreensão.

Tabela 3.3: Tabela Exemplo

bin	$Velocidade_{Rotor}$	$Temperatura_{componente}$
2	10.25	16.77
4	11.51	21.80
1	10.01	23.40
5	11.65	26
4	11.40	26.12
9	13.98	25.65

Após organizarmos todos os dados nos seus respectivos bins podemos seguir para o passo seguinte. Passo esse que consiste no cálculo da média de todos os valores de velocidade do rotor e temperatura. O valor esperado da velocidade do rotor pode ser calculado seguindo 3.8.

$$\bar{n}_j = \frac{1}{k} \sum_{i=1}^k n_{ij} \quad (i = 1, 2, \dots, k \quad j = 1, 2, \dots, d) \quad (3.8)$$

onde \bar{n}_j é o valor da média da velocidade do rotor no bin j , k é o número de observações de velocidade no bin j e n_{ij} é o valor de velocidade do rotor no bin. O mesmo será feito para os valores de temperatura em todos os bins.

Por fim, ficaremos com dois vectores. Um referente às médias de Velocidade do Rotor em todos os bins e outro vector com as médias dos valores de Temperatura em todos os bins.

Com vista a obter um valor de temperatura em função da velocidade do rotor, é utilizado um método de *data fitting* disponível no Matlab. Definiremos que os valores serão ajustados numa curva polinomial de 2 grau, onde o eixo das abcissas representará a velocidade do rotor e o eixo das ordenadas a temperatura.

Daqui retiramos os valores dos coeficientes obtendo finalmente a função desejada $Temp(n) = a * n^2 + b * n + c$ (Figura 3.6), sendo que n diz respeito à velocidade do rotor. O valor $Temp$ devolvido pela função é o nosso *Limite Superior Variável*, β_2 , onde um valor pequeno revela um bom estado do componente.




Figura 3.6: Demonstração gráfica da função $Temp(n)$.

3.4.1.3 Grau de Deterioração, g

Uma vez calculados os limites inferiores e superiores variáveis, resta calcular o *grau de deterioração* g . O grau de deterioração tenta indicar o estado de um componente crítico, relacionando a sua temperatura com a velocidade do rotor pela seguinte função:

$$g(n) = \frac{x(n) - \beta_1(n)}{\beta_2(n) - \beta_1(n)}, \quad (3.9)$$

em que, $\beta_1(n)$ e $\beta_2(n)$ dizem respeito aos limites inferior e superiores variáveis respectivamente; n a velocidade do rotor no instante t e x a respectiva temperatura do componente.

Qualitativamente o grau de deterioração pode ser dividido em 4 categorias, como referido na secção 3.1 e exemplificado na Tabela 3.4.

Tabela 3.4: Categorias do grau de deterioração.

<i>Grau de deterioração</i>	
<i>Categoria</i>	<i>Valor de Intervalo</i>
Excelente	$g \in [0, 0.30]$
Bom	$g \in [0.30, 0.55]$
Alerta	$g \in [0.55, 0.80]$
Perigo	$g \in [0.80, \infty]$

Um estado “Excelente” do componente indica que o componente está em óptimas condições e que os valores de temperatura estão dentro do esperado. “Bom” indica que o componente está em condições normais operacionais, no entanto, alguns valores de temperatura podem fugir um pouco à regra. O estado “Alerta” revela que o componente funciona com algum falta de eficiência, vários valores de temperatura estão fora do intervalo de valores aceitáveis e como tal, é necessária decisão por parte do responsável se algum acção será tomada. Já “Perigo” indica que todos os valores de temperatura estão fora dos valores aceitáveis operacionais e que continuando operacional pode levar a dano permanente do componente e danificar ou levar à falha do sistema de energia.

3.4.2 Aplicação do Algoritmo

Explicada e demonstrada toda a construção do algoritmo, segue por fim a aplicação do mesmo nos dados que nos foram fornecidos.

Serão demonstrados 2 diferentes casos de estudo enquanto os resultados de outras aplicações do algoritmo serão disponibilizadas em apêndice.

3.4.2.1 Caso 1

Começando por rever o documento de dados de eventos, identificamos que a caixa de velocidades da turbina 2, no dia 233 do ano de 2011, foi substituída por completo. O alvo de aplicação do algoritmo será esta mesma turbina 2, analisando os valores de velocidade do rotor e os respectivos valores de temperatura do rolamento na caixa de velocidades.

De acordo com a equação 3.2 e sabendo que a substituição foi feita no dia 233 obtemos $R = 33550$ registos. Prosseguindo a triagem de dados, nomeadamente a condição referida em 3.3, reduzimos o número de registos para $R = 17554$, que revela uma significativa alteração na dimensão dos dados.

Esta primeira análise de dados resulta numa matriz $17554 \cdot 2$ com os valores de velocidade do rotor e as temperaturas do rolamento na caixa de velocidades.

Os seguintes histogramas apresentados nas Figuras 3.7 e 3.8 permitem ter uma noção da distribuição de valores da velocidade do rotor e da temperatura do rolamento, onde cada barra (com cores diferentes) representa cada uma das 8 turbinas.




Figura 3.7: Histograma $Velocidade_{rotor}$




Figura 3.8: Histograma $Temperatura_{caixaVelocidades}$

Pela Figura 3.8 podemos observar que apenas algumas turbinas apresentam valores de temperatura do rolamento da caixa de velocidades superiores a 70°C.

Limite Superior Variável β_2

Finalizada o tratamento de dados podemos começar o calculo do limite inferior β_2 .

Começando pelo cálculo de d através da equação 3.7 temos que $d = 12$ bins. Através da função *histcounts* do Matlab os valores de velocidade do rotor e de temperatura são divididos pelos 12 bins, cuja distribuição pode ser vista no histograma apresentado na Figura 3.9.




Figura 3.9: Histograma da distribuição dos valores de $Velocidade_{rotor}$ pelos 12bins.

O próximo passo consiste no cálculo das médias da $Velocidade_{rotor}$ e $Temperatura_{caixaVelocidades}$ em cada bin, que podem ser vistas na Tabela 3.5, tendo em atenção que os valores forem arredondados para 1 casa decimal para efeitos de amostra.

Tabela 3.5: Médias de $Velocidade_{rotor}$ e $Temperatura_{caixaVelocidades}$

	Bins											
	1	2	3	4	5	6	7	8	9	10	11	12
$Velocidade_{rotor}$	9.8	10.3	10.8	11.3	11.9	12.4	12.9	13.5	14.0	14.5	15.0	15.4
$Temperatura_{caixaVelocidades}$	59.3	57.4	59.3	60.2	60.2	60.6	60.8	61.2	61.6	62.5	64.0	63.8

Resta a aplicação do Matlab *Curvefitting*, utilizando as médias previamente calculadas, para obter um valor de temperatura em função da velocidade do rotor, segundo uma função polinomial de 2º grau.

Finalmente obtemos a nossa função $Temp(n) = 0.0589 * n^2 - 0.5445 * n + 58.2438$, que pode ser vista na Figura 3.10. Temos então β_2 visto que $Temp(n)$ equivale ao nosso limite superior variável.




Figura 3.10: Função $Temp(n) = 0.0589 * n^2 - 0.5445 * n + 58.2438$

Limite Inferior Variável β_1

Para calculo do nosso limite inferior variável β_1 comecemos pela normalização da matriz *Velocidade do Rotor* para que o algoritmo de clustering Fuzzy C-means possa ser aplicado.

Recordando que β_1 é determinado para cada instante t , isto é, para cada número de registo, os valores que serão apresentados serão uma demonstração de um desses registos. Utilizando a lógica fuzzy c-means no registo $R = 15004$ com 2 clusters, obtemos a seguinte matriz *membership*:

$$Membership = \begin{bmatrix} 0.0763 & 0.9690 & 0.9983 & 0.0223 & 0.2582 & 0.0139 & 0.0943 & 0.9242 \\ 0.9237 & 0.0310 & 0.0017 & 0.9777 & 0.7418 & 0.9861 & 0.9057 & 0.0758 \end{bmatrix}$$

Resultando na organização das turbinas da seguinte forma (Tabela 3.6),

Tabela 3.6: Grupos de Turbinas (2 clusters) Caso 1

Grupos de Turbinas pós-clustering					
Grupo 1			Grupo 2		
Turbina	$V_{rotor}(rpm)$	Temp(°C)	Turbina	$V_{rotor}(rpm)$	Temp(°C)
2	14.26	61.14	1	10.58	42.13
3	13.83	70.66	4	11.09	62.40
8	13.24	61.50	5	12.32	63.65
			6	11.72	65.06
			7	12.04	66.08

Verificando a condição $\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$ é fácil verificar que no Grupo 2 esta condição não é respeitada $\Delta_n = 12.32 - 10.58 = 1.74 > 1 \text{ rpm}$ o que resulta numa próxima iteração da função fuzzy, isto é, a divisão por 3 clusters, resultando na seguinte matriz membership e consequentes grupos (Tabela 3.7).

$$Membership = \begin{bmatrix} 0,0060 & 0,9576 & 1 & 0,0077 & 0,0269 & 0,0219 & 0,0004 & 0,7503 \\ 0,0288 & 0,0302 & 0 & 0,0610 & 0,9448 & 0,8539 & 0,9992 & 0,2016 \\ 0,9652 & 0,0123 & 0 & 0,9313 & 0,0282 & 0,1242 & 0,0004 & 0,0480 \end{bmatrix}$$

Tabela 3.7: Grupos de Turbinas(3 clusters) Caso 1

Grupos de Turbinas pós-clustering								
Grupo 1			Grupo 2			Grupo 3		
Turbina	Vrotor	Temp	Turbina	Vrotor	Temp	Turbina	Vrotor	Temp
2	14.22	64.14	5	12.32	63.65	1	10.58	42.13
3	13.83	70.66	6	11.72	65.06	4	11.09	62.40
8	13.24	61.50	7	12.04	66.08			

Uma vez que a condição $\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$ já é respeitada por todos os grupos, e lembrando que a turbina em estudo é a Turbina 2, presente no Grupo 1, é retirado o valor mínimo de temperatura, $T = 61.50^\circ\text{C}$ (a negrito). Esse valor, corresponde ao *Limite Inferior Variável*, $\beta_1 = 61.50$ no instante de tempo t ou seja, registro $R = 15004$.

Grau de deterioração g

Após calculados os limites inferior e superior, o grau de deterioração quando $R = 15004$, a que corresponde um valor de velocidade do rotor $n = 14.23 \text{ rpm}$, pode ser calculado de acordo com a equação 3.10:

$$g(14.23) = \frac{x(14.23) - \beta_1(14.23)}{\beta_2(14.23) - \beta_1(14.23)} = \frac{64.14 - 61.50}{62.41 - 61.50} = 2.88, \quad (3.10)$$

O que segundo a Tabela 3.4 revela um valor “Perigo” do grau de deterioração com $g \in [0.80, \infty]$, no entanto um valor um pouco mais alto que o esperado. Ainda assim, considerando que a Caixa de Velocidades foi substituída poderia ser um valor aceitável.

Avaliando a função *grau de deterioração* até ao momento da reparação ($N \simeq 17500$), isto é, $g(n)$ para todos os dados até a falha, é possível verificar uma tendência crescente do *grau de deterioração* (Figura 3.11). No entanto, podemos também interpretar que algo não está de acordo com o esperado, como por exemplo valores negativos do *grau de deterioração*, ($g < 0$).




Figura 3.11: Grau de deterioração

Considerando que determinados valores se podem encontrar excepcionalmente fora do intervalo definido para o grau de deterioração e com o intuito de tentar perceber e avaliar a deterioração do componente mais perto da falha, foram tentadas outras abordagens. Esperando que a deterioração de um componente siga uma evolução crescente e polinomial, uma regressão polinomial da função foi testada e comparada para todas as turbinas com o objectivo de perceber melhor a evolução do estado do componente assim como a eficácia do algoritmo desenvolvido. A Figura 3.12, representa esta regressão polinomial da função. Já as Figuras 3.13 e 3.14 representam partes do gráfico que foram ampliadas, também com o objectivo de fazer uma melhor interpretação avaliação dos resultados obtidos.




Figura 3.12: Grau de deterioração (regressão polinomial 2º grau).




Figura 3.13: Grau de deterioração ampliado.

A análise a estes gráficos e tendo em atenção a que intervalos de tempo/registos a que dizem respeito é possível identificar uma maior dispersão do grau de deterioração, assim como um valor mais elevado (Figura 3.12), mais perto do momento de substituição




Figura 3.14: Grau de deterioração ampliado.

da caixa de velocidades (Figura 3.13) especialmente quando comparado a momentos de tempo anteriores (Figura 3.14).

No entanto, através da análise da evolução do grau de deterioração não é conclusivo que o algoritmo apresentado revela com eficiência o estado do componente.

3.4.2.2 Caso 2

Consultando uma vez mais o registo de eventos, sabemos que no dia 214 de 2013 a turbina 3 foi alvo de reparação, revelando um problema num rolamento também na caixa de velocidades.

Temos então que $R = 30816$, que após a condição de reduzir os registos para intervalos onde a velocidade do rotor $\in [9.6, 16.9]$ rpm resulta num $R = 15593$, cerca de metade da dimensão inicial. A distribuição de valores de $Velocidade_{rotor}$ e $Temperatura_{componente}$ podem ser vistas nos histogramas das Figuras 3.15 e 3.16.




Figura 3.15: Histograma $Velocidade_{rotor}$.




Figura 3.16: Histograma $Temperatura_{componente}$.

Limite Superior Variável β_2

Seguindo a equação $d = \frac{n_{max} - n_{min}}{0.5}$ temos que $d = 11$ bins. A função histcounts do matlab executa a divisão dos valores de velocidade do rotor e temperatura do rolamento da caixa de velocidades por esses mesmos 11 bins, cuja distribuição pode ser observada na Figura 3.17.




Figura 3.17: Histograma distribuição dos dados pelos bins.

A média dos valores de velocidade do rotor e de temperatura de rolamento da caixa de velocidades podem ser vistos na Tabela 3.8.

Tabela 3.8: Valores de média em cada bin

	<i>Bins</i>										
	1	2	3	4	5	6	7	8	9	10	11
VelocidadeRotor	10.00	10.31	10.82	11.30	11.8	12.30	12.79	13.28	13.79	14.29	14.78
TemperaturaRolamento	55.95	57.71	60.60	62.26	63.81	65.00	66.39	67.34	68.60	71.05	73.36

Por fim, com vista a obtermos a função $Temp(n)$, é utilizada uma regressão polinomial de segundo grau, da qual concluímos que $Temp(n) = -0.1175 * n^2 + 6.184 * n + 6.550$ cujo gráfico esta presente na Figura 3.18. Equação que nos permite obter o limite superior Variável β_2 .




Figura 3.18: Gráfico da função $Temp(n) = -0.1175 * n^2 + 6.184 * n + 6.55$.

Limite Inferior Variável β_1

Após normalização da matriz de velocidade do rotor, o algoritmo Fuzzy C-means é aplicado. Utilizando a lógica fuzzy C-means, em que para efeitos de demonstração será utilizado o registo $R = 10000$ e começando uma vez mais com 2 clusters, obtemos:

$$Membership = \begin{bmatrix} 0.9982 & 0 & 0.9942 & 0.9905 & 0.9994 & 0.9967 & 0.9961 & 0.9980 \\ 0.0018 & 1 & 0.0058 & 0.0095 & 0.0006 & 0.0033 & 0.0039 & 0.0020 \end{bmatrix}$$

Resultando na seguinte distribuição das turbinas pelos 2 grupos (Tabela 3.9),

Tabela 3.9: Grupos de Turbinas Caso 2

Grupos de Turbinas pós-clustering					
Grupo 1			Grupo 2		
Turbina	Vrotor	Temp	Turbina	Vrotor	Temp
1	10.38	57.07	2	13.32	50.01
3	10.47	62.33			
4	10.53	57.50			
5	10.18	57.00			
6	10.07	57.38			
7	10.05	58.13			
8	10.11	50.23			

Tendo em atenção que a condição $\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$ é respeitada em ambos os grupos e lembrando que a turbina em estudo é a Turbina 3, situada no Grupo 1,

então $T_{min} = 50.23$ °C corresponde ao *Limite Inferior Variável*, $\beta_1 = 50.23$ (assinalado a negrito) para o registo $R = 10000$.

Grau de deterioração g

Uma vez calculados os limites inferior e superior, o grau de deterioração o grau de deterioração em $R = 10000$, cuja *velocidadedorotor* = 10.63 rpm pode ser calculado de acordo com a equação 3.11:

$$g(10.63) = \frac{x(10.63) - \beta_1(10.63)}{\beta_2(10.63) - \beta_1(10.63)} = \frac{62.33 - 50.23}{58.54 - 50.23} = 1.46, \quad (3.11)$$

Consultando o quadro (Tabela 3.4) verificamos que se encontra no intervalo $g \in [080, \infty]$ o que revela um valor “Perigo” do grau de deterioração. Valor esse, que considerando que o rolamento da caixa de velocidades necessitou de reparação, faz sentido.

Analisando o gráfico da Figura 3.19 é possível observar uma tendência crescente do grau de deterioração até ao registo $R = 10000$, que acaba por ser comprovado na regressão polinomial apresentada de seguida (Figura 3.20). No entanto, a partir desse momento o grau de deterioração começa estranhamente a diminuir.

Este resultado vem apenas comprovar o que já tinha sido dito no *Caso 1*, nomeadamente a duvidosa eficiência deste algoritmo para facultar um grau de deterioração de um componente.




Figura 3.19: Gráfico deterioração Caso 2.




Figura 3.20: Regressão polinomial 2º grau Caso 2.

Conclusão

Técnicas de controlo de condição têm sido alvo de um crescente interesse por parte da comunidade científica e industrial, pois é claro que estas técnicas, quando permitindo um prognóstico fiável poderão reduzir em grande escala os investimentos em manutenção e melhorar os resultados globais das organizações. Técnicas utilizando inteligência artificial, como *machine learning* poderão ter grande impacto e são por isso, uma das áreas que maior interesse tem despertado e um crescente número de publicações tem sido perceptível.

Este documento apresenta uma revisão de técnicas e métodos actual, destacando de certo modo a sua aplicação em turbinas eólicas, onde diferentes técnicas e algoritmos são descritos com relativa profundidade.

Deste estudo realizado, é feita a interpretação e implementação de um algoritmo eleito do estado da arte na área da aplicação da inteligência computacional no controlo de condição de turbinas eólicas que permite encontrar um grau de deterioração de um componente relacionando os valores de temperatura com a velocidade do rotor.

O método de prognóstico desenvolvido e aplicado tem o objectivo de prever o futuro estado do componente e agir de acordo com essa mesma previsão, tomando as decisões de manutenção necessárias permitindo uma significativa redução nos custos de operação e manutenção de um parque eólico e assim melhorar os seus resultados. Um dos factores relevantes desta técnica é serem apenas necessários dados de temperatura e de velocidade do rotor, o que implica um menor investimento no que toca à aquisição de dados, visto que são apenas necessários sensores de temperatura e de velocidade do rotor.

No entanto, ao longo da aplicação deste algoritmo surgiram vários contratempos e adversidades que, apesar do esforço e diferentes abordagens tomadas, não permite que afirmemos com total segurança que o algoritmo retrata com fiabilidade o estado actual do componente, como aliás foi possível entender nos casos de estudo apresentados. Estes resultados incoerentes podem dever-se a diversos factores, tais como: dados corrompidos, quais motivos que levaram às substituições de componentes efectuadas, diferenças no algoritmo desenvolvido comparativamente ao apresentado por Y.Hu et al., entre outras,

crendo que uma das mais relevantes será a diferença no volume de dados, uma vez que na publicação de Y.Hu et al. o algoritmo é testado num parque eólico composto por mais de 30 turbinas enquanto que a aplicação do algoritmo desenvolvido e apresentado nesta dissertação terá sido apenas em 8 turbinas eólicas.

Estes factores levaram a que no fim, apesar de todos os esforços realizados, não fosse possível confirmar a fiabilidade do algoritmo em revelar o grau de deterioração do componente.

De referir ainda que o algoritmo desenvolvido, bem como todas as ferramentas criadas para o estudo e interpretação de resultados, estão prontas a ser aplicadas a qualquer base de dados de um parque eólico.

4.1 Trabalhos Futuros

Este trabalho partiu com a ideia de, uma vez confirmada a fiabilidade do algoritmo desenvolvido, este algoritmo fosse aplicado a diferentes parques eólicos em tempo real, permitindo o acompanhamento do estado dos componentes da turbina eólica, avaliando o seu grau de deterioração e com isso conseguir planejar estratégias de manutenção eficientes de modo a melhorar a produção de energia do parque eólico.

Uma vez que os resultados das ferramentas desenvolvidas não nos permitiram confirmar a fiabilidade do algoritmo pelas razões anteriormente descritas, surge então a proposta de que, num futuro próximo, o algoritmo desenvolvido seja aplicado a parques eólicos de maiores dimensões, isto é, com um maior número de turbinas, afim de confirmar a sua fiabilidade. Uma vez então verificada a sua fiabilidade, o algoritmo pode ser incorporado numa técnica de manutenção CBM *on-line*, onde o acompanhamento em tempo real dos dados SCADA permite um prognóstico do estado componente, contribuindo deste modo para uma manutenção mais eficiente e consequente melhoria dos resultados globais do parque eólico.

Da revisão bibliográfica de manutenção aplicada a turbinas eólicas realizada, destacam-se também os trabalhos de P.Bangalore et al. [97], que apresenta uma estrutura de gestão de manutenção chamada *SEMS (Self Evolving Maintenance Scheduler)* que previu uma falha na caixa de velocidades com 2 meses de antecedência, e de R.Carrato [104], que propõe um método para avisos e detecção de falhas utilizando técnicas de *clustering* e distância de Mahalanobis onde vantagens como a fácil integração em sistemas SCADA e a sua capacidade para detectar falhas em tempo real, como a possibilidade de estender o método para análise estrutural dos elementos da turbina, tornam o método aliciante.

Bibliografia

- [1] More4Core-project. “Challenges for industry in north-west europe”. Em: ed. por BEMAS. 2016. URL: <http://www.more4core.eu/wp-content/uploads/2016/06/Challenges-for-industry-in-North-West-Europe.pdf>.
- [2] V. T. Tran e B. S. Yang. “An intelligent condition-based maintenance platform for rotating machinery”. Em: *Expert Systems with Applications* 39.3 (2012), pp. 2977–2988. ISSN: 09574174. DOI: 10.1016/j.eswa.2011.08.159. URL: <http://dx.doi.org/10.1016/j.eswa.2011.08.159>.
- [3] R. Skjong. “Safety and Reliability”. Em: *Criteria for establishing risk acceptance* (2003), pp. 1461–1468.
- [4] V. T.R. C. of Finland. “Prognostics for industrial machinery availability: Final seminar”. Em: *VTT Symposium (Valtion Teknillinen Tutkimuskeskus)* 243 (2006). ISSN: 03579387.
- [5] A. Parida e U. Kumar. “Maintenance productivity and performance measurement”. Em: *Handbook of Maintenance Management and Engineering* (2009), pp. 17–41. DOI: 10.1007/978-1-84882-472-0_2. URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-80052253498&doi=10.1007%2F978-1-84882-472-0%2F2&partnerID=40&md5=d55a46ef7f637ce8218745c44ee068e3>.
- [6] J. Knezevic. *Reliability, maintainability, and supportability: a probabilistic approach*. Ed. por McGraw-Hill. 1993.
- [7] Y. Peng, M. Dong e M. J. Zuo. “Current status of machine prognostics in condition-based maintenance: A review”. Em: *International Journal of Advanced Manufacturing Technology* 50.1-4 (2010), pp. 297–313. ISSN: 02683768. DOI: 10.1007/s00170-009-2482-0. arXiv: 0208024 [gr-qc].
- [8] A. Heng, S. Zhang, A. C. Tan e J. Mathew. “Rotating machinery prognostics: State of the art, challenges and opportunities”. Em: *Mechanical Systems and Signal Processing* 23.3 (2009), pp. 724–739. ISSN: 08883270. DOI: 10.1016/j.ymssp.2008.06.009. arXiv: 0208024 [gr-qc].

- [9] H. P. Bloch e F. K. Gettner. *Machinery Failure Analysis and Troubleshooting*. Gulf Publishing Company, 1990. ISBN: 0884156621. DOI: 10.1007/978-90-481-3132-7.
- [10] A. Bousdekis, B. Magoutas, D. Apostolou e G. Mentzas. “A proactive decision making framework for condition-based maintenance”. Em: *Industrial Management & Data Systems* 115.7 (2015), pp. 1225–1250. ISSN: 0263-5577. DOI: 10.1108/IMDS-03-2015-0071. URL: <http://www.emeraldinsight.com/doi/10.1108/IMDS-03-2015-0071>.
- [11] L. Hammer. *P-F Curve*. 2017. URL: http://www.dezide.com/static{_}knowledge{_}at{_}the{_}right{_}time/ (acedido em 10/12/2017).
- [12] D. Goyal e B. S. Pabla. “Condition based maintenance of machine tools-A review”. Em: *CIRP Journal of Manufacturing Science and Technology* 10 (2015), pp. 24–35. ISSN: 17555817. DOI: 10.1016/j.cirpj.2015.05.004. URL: <http://dx.doi.org/10.1016/j.cirpj.2015.05.004>.
- [13] A. Shagluf, A. P. Longstaff e S Fletcher. “Maintenance Strategies to Reduce Downtime Due to Machine Positional Errors”. Em: SEPTEMBER (2014), pp. 111–118. DOI: 10.14195/978-972-8954-42-0_25.
- [14] R. Ahmad e S. Kamaruddin. “An overview of time-based and condition-based maintenance in industrial application”. Em: *Computers and Industrial Engineering* 63.1 (2012), pp. 135–149. ISSN: 03608352. DOI: 10.1016/j.cie.2012.02.002. URL: <http://dx.doi.org/10.1016/j.cie.2012.02.002>.
- [15] A. Gupta e C. Lawsirirat. “Strategically optimum maintenance of monitoring-enabled multi-component systems using continuous-time jump deterioration models”. Em: *Journal of Quality in Maintenance Engineering* 12.3 (2006), pp. 306–329. ISSN: 1355-2511. DOI: 10.1108/13552510610685138. arXiv: [/dx.doi.org/10.1108/BIJ-10-2012-0068](http://dx.doi.org/10.1108/BIJ-10-2012-0068) [http:]. URL: <http://www.emeraldinsight.com/doi/10.1108/13552510610685138>.
- [16] *SS-EN 13306, 2001, p. 16*.
- [17] S. Martin-del Campo e F. Sandin. “Online feature learning for condition monitoring of rotating machinery”. Em: *Engineering Applications of Artificial Intelligence* 64.April (2017), pp. 187–196. ISSN: 09521976. DOI: 10.1016/j.engappai.2017.06.012. URL: <http://dx.doi.org/10.1016/j.engappai.2017.06.012>.
- [18] A. K. Jardine, D. Lin e D. Banjevic. “A review on machinery diagnostics and prognostics implementing condition-based maintenance”. Em: *Mechanical Systems and Signal Processing* 20.7 (2006), pp. 1483–1510. ISSN: 08883270. DOI: 10.1016/j.ymssp.2005.09.012. arXiv: 0208024 [gr-qc].

- [19] A. S. Morris e R. Langari. "Data Acquisition and Signal Processing". Em: *Measurement and Instrumentation*. Academic Press, 2016. Cap. 6, pp. 145–175. ISBN: 9786090211977. DOI: 10.1016/B978-0-12-800884-3.00006-X. URL: <http://linkinghub.elsevier.com/retrieve/pii/B978012800884300006X>.
- [20] R. Xu e C. Kwan. "Robust Isolation Of Sensor Failures". Em: *Asian Journal of Control* 5.1 (2008), pp. 12–23. ISSN: 15618625. DOI: 10.1111/j.1934-6093.2003.tb00093.x. URL: <http://doi.wiley.com/10.1111/j.1934-6093.2003.tb00093.x>.
- [21] J. Lee, F. Wu, W. Zhao, M. Ghaffari, L. Liao e D. Siegel. "Prognostics and health management design for rotary machinery systems - Reviews, methodology and applications". Em: *Mechanical Systems and Signal Processing* 42.1-2 (2014), pp. 314–334. ISSN: 08883270. DOI: 10.1016/j.ymssp.2013.06.004. URL: <http://dx.doi.org/10.1016/j.ymssp.2013.06.004>.
- [22] I. Howard, S. Jia e J. Wang. "The dynamic modelling of a spur gear in mesh including friction and a crack". Em: *Mechanical Systems and Signal Processing* 15.5 (2001), pp. 831–853. ISSN: 08883270. DOI: 10.1006/mssp.2001.1414.
- [23] A. A. Tabrizi. "Development of new fault detection methods of rotating machines (rolling bearing)". Tese de doutoramento. Politecnico di Torino, 2015. DOI: 10.6092/polito/porto/2598388.
- [24] B. S. Yang, D. S. Lim e A. C. C. Tan. "VIBEX: An expert system for vibration fault diagnosis of rotating machinery using decision tree and decision table". Em: *Expert Systems with Applications* 28.4 (2005), pp. 735–742. ISSN: 09574174. DOI: 10.1016/j.eswa.2004.12.030.
- [25] C. Nan, F. Khan e M. T. Iqbal. "Real-time fault diagnosis using knowledge-based expert system". Em: *Process Safety and Environmental Protection* 86.1 B (2008), pp. 55–71. ISSN: 09575820. DOI: 10.1016/j.psep.2007.10.014.
- [26] A. Ayodeji, Y. kuo Liu e H. Xia. "Knowledge base operator support system for nuclear power plant fault diagnosis". Em: *Progress in Nuclear Energy* 105.June 2017 (2018), pp. 42–50. ISSN: 01491970. DOI: 10.1016/j.pnucene.2017.12.013. URL: <https://doi.org/10.1016/j.pnucene.2017.12.013>.
- [27] Q. Zhou, P. Yan e Y. Xin. "Research on a knowledge modelling methodology for fault diagnosis of machine tools based on formal semantics". Em: *Advanced Engineering Informatics* 32 (2017), pp. 92–112. ISSN: 14740346. DOI: 10.1016/j.aei.2017.01.002. URL: <http://dx.doi.org/10.1016/j.aei.2017.01.002>.
- [28] T. V. Tung e B.-S. Yang. "Machine Fault Diagnosis and Prognosis: The State of The Art". Em: *International Journal of Fluid Machinery and Systems* 2.1 (2009), pp. 61–71. ISSN: 1882-9554. DOI: 10.5293/IJFMS.2009.2.1.061. URL: <http://koreascience.or.kr/journal/view.jsp?kj=OCGKEU\&py=2009\&vnc=v2n1\&sp=61>.

- [29] X. Lou e K. A. Loparo. "Bearing fault diagnosis based on wavelet transform and fuzzy inference". Em: *Mechanical Systems and Signal Processing* 18.5 (2004), pp. 1077–1095. ISSN: 08883270. DOI: 10.1016/S0888-3270(03)00077-3.
- [30] D. Wang, Y. Zhao, C. Yi, K. L. Tsui e J. Lin. "Sparsity guided empirical wavelet transform for fault diagnosis of rolling element bearings". Em: *Mechanical Systems and Signal Processing* 101 (2018), pp. 292–308. ISSN: 10961216. DOI: 10.1016/j.ymssp.2017.08.038. URL: <http://dx.doi.org/10.1016/j.ymssp.2017.08.038>.
- [31] H. Darong, K. Lanyan, C. Xiaoyan, Z. Ling e M. Bo. "Fault diagnosis for the motor drive system of urban transit based on improved Hidden Markov Model". Em: *Microelectronics Reliability* 82 (2018), pp. 179–189. ISSN: 0026-2714. DOI: 10.1016/j.microrel.2018.01.017.
- [32] Z. Chen, S. Deng, X. Chen, C. Li, R. V. Sanchez e H. Qin. "Deep neural networks-based rolling bearing fault diagnosis". Em: *Microelectronics Reliability* 75 (2017), pp. 327–333. ISSN: 00262714. DOI: 10.1016/j.microrel.2017.03.006. URL: <http://dx.doi.org/10.1016/j.microrel.2017.03.006>.
- [33] G. Qi, Z. Zhu, K. Erqinhu, Y. Chen, Y. Chai e J. Sun. "Fault-diagnosis for reciprocating compressors using big data and machine learning". Em: *Simulation Modelling Practice and Theory* 80 (2018), pp. 104–127. ISSN: 1569190X. DOI: 10.1016/j.simpat.2017.10.005.
- [34] Y. Lei, N. Li, L. Guo, N. Li, T. Yan e J. Lin. "Machinery health prognostics: A systematic review from data acquisition to RUL prediction". Em: *Mechanical Systems and Signal Processing* 104 (2018), pp. 799–834. ISSN: 10961216. DOI: 10.1016/j.ymssp.2017.11.016.
- [35] P. Paris e F Erdogan. "A critical analysis of crack propagation laws". Em: *Journal of Basic Engineering* 85.4 (1963), pp. 528–533. ISSN: 00219223. DOI: 10.1115/1.3656900. URL: <http://fluidsengineering.asmedigitalcollection.asme.org/article.aspx?articleid=1431537>.
- [36] M. A. Haile, J. C. Riddick e A. H. Assefa. "Robust Particle Filters for Fatigue Crack Growth Estimation in Rotorcraft Structures". Em: *IEEE Transactions on Reliability* 65.3 (2016), pp. 1438–1448. ISSN: 00189529. DOI: 10.1109/TR.2016.2590258.
- [37] Y. Lei, N. Li, S. Gontarz, J. Lin, S. Radkowski e J. Dybala. "A Model-Based Method for Remaining Useful Life Prediction of Machinery". Em: *IEEE Transactions on Reliability* 65.3 (2016), pp. 1314–1326. ISSN: 00189529. DOI: 10.1109/TR.2016.2570568.

-
- [38] J. Sun, H. Zuo, W. Wang e M. G. Pecht. “Prognostics uncertainty reduction by fusing on-line monitoring data based on a state-space-based degradation model”. Em: *Mechanical Systems and Signal Processing* 45.2 (2014), pp. 396–407. ISSN: 08883270. DOI: 10.1016/j.ymssp.2013.08.022. URL: <http://dx.doi.org/10.1016/j.ymssp.2013.08.022>.
 - [39] Y. Li, S. Billington, C. Zhang, T. Kurfess, S. Danyluk e S. Liang. “Adaptive prognostics for rolling element bearing condition”. Em: *Mechanical Systems and Signal Processing* 13.1 (1999), pp. 103–113. ISSN: 08883270. DOI: 10.1006/mssp.1998.0183. URL: <http://www.sciencedirect.com/science/article/pii/S0888327098901832>.
 - [40] D. An, N. H. Kim e J. H. Choi. “Practical options for selecting data-driven or physics-based prognostics algorithms with reviews”. Em: *Reliability Engineering and System Safety* 133 (2015), pp. 223–236. ISSN: 09518320. DOI: 10.1016/j.res.2014.09.014. URL: <http://dx.doi.org/10.1016/j.res.2014.09.014>.
 - [41] X. S. Si, W. Wang, C. H. Hu e D. H. Zhou. “Remaining useful life estimation - A review on the statistical data driven approaches”. Em: *European Journal of Operational Research* 213.1 (2011), pp. 1–14. ISSN: 03772217. DOI: 10.1016/j.ejor.2010.11.018. URL: <http://dx.doi.org/10.1016/j.ejor.2010.11.018>.
 - [42] Y. Lei, N. Li e J. Lin. “A New Method Based on Stochastic Process Models for Machine Remaining Useful Life Prediction”. Em: *IEEE Transactions on Instrumentation and Measurement* 65.12 (2016), pp. 2671–2684. ISSN: 00189456. DOI: 10.1109/TIM.2016.2601004.
 - [43] Z. S. Yea e M. Xie. “Stochastic modelling and analysis of degradation for highly reliable products”. Em: *Applied Stochastic Models in Business and Industry* 31.1 (2005), pp. 16–32. ISSN: 15264025. DOI: 10.1002/asmb.2063.
 - [44] C. Bunks, D. McCarthy e T. Al-Ani. “Condition-based maintenance of machines using hidden Markov models”. Em: *Mechanical Systems and Signal Processing* 14.4 (2000), pp. 597–612. ISSN: 08883270. DOI: 10.1006/mssp.2000.1309.
 - [45] A. G. Wilson e R. P. Adams. “Gaussian Process Kernels for Pattern Discovery and Extrapolation”. Em: 28 (2013). arXiv: 1302.4245. URL: <http://arxiv.org/abs/1302.4245>.
 - [46] N. Z. Gebraeel, M. A. Lawley, R. Li e J. K. Ryan. “Residual-life distributions from component degradation signals: A Bayesian approach”. Em: *IIE Transactions (Institute of Industrial Engineers)* 37.6 (2005), pp. 543–557. ISSN: 0740817X. DOI: 10.1080/07408170590929018. arXiv: arXiv:1011.1669v3.
 - [47] I. Portugal, P. Alencar e D. Cowan. “The use of machine learning algorithms in recommender systems: A systematic review”. Em: *Expert Systems with Applications* 97 (2018), pp. 205–227. ISSN: 09574174. DOI: 10.1016/j.eswa.2017.12.020. arXiv: 1511.05263. URL: <https://doi.org/10.1016/j.eswa.2017.12.020>.

- [48] M. Schwabacher e K. Goebel. "A survey of artificial intelligence for prognostics". Em: *Association for the Advancement of Artificial Intelligence AAAI Fall Symposium 2007* (2007), pp. 107–114.
- [49] L. Zhou, S. Pan, J. Wang e A. V. Vasilakos. "Machine learning on big data: Opportunities and challenges". Em: *Neurocomputing* 237. September 2016 (2017), pp. 350–361. ISSN: 18728286. DOI: 10.1016/j.neucom.2017.01.026.
- [50] W. Q. Wang, M. F. Golnaraghi e F. Ismail. "Prognosis of machine health condition using neuro-fuzzy systems". Em: *Mechanical Systems and Signal Processing* 18.4 (2004), pp. 813–831. ISSN: 08883270. DOI: 10.1016/S0888-3270(03)00079-7.
- [51] WCEAM. "Second World Congress on Engineering Asset Management". Em: 2007, pp. 1195–1206.
- [52] R. Zemouri e R. Gouriveau. "Towards accurate and reproducible predictions for prognostic: An approach combining a RRBf Network and an AutoRegressive model". Em: *IFAC Proceedings Volumes (IFAC-PapersOnline)* 1.PART 1 (2010), pp. 140–145. ISSN: 14746670. DOI: 10.3182/20100701-2-PT-4012.00025.
- [53] M. Elforjani. "Estimation of Remaining Useful Life of Slow Speed Bearings Using Acoustic Emission Signals". Em: *Journal of Nondestructive Evaluation* 35.4 (2016), pp. 1–16. ISSN: 15734862. DOI: 10.1007/s10921-016-0378-0.
- [54] Z. Tian. "An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring". Em: *Journal of Intelligent Manufacturing* 23.2 (2012), pp. 227–237. ISSN: 09565515. DOI: 10.1007/s10845-009-0356-9.
- [55] R. Zemouri, D. Racocanu e N. Zerhouni. "Recurrent radial basis function network for time-series prediction". Em: *Engineering Applications of Artificial Intelligence* 16.5-6 (2003), pp. 453–463. ISSN: 09521976. DOI: 10.1016/S0952-1976(03)00063-0.
- [56] S. Amin, C. Byington e M. Watson. "Fuzzy inference and fusion for health state diagnosis of hydraulic pumps and motors". Em: *Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS 2005* (2005), pp. 13–18. DOI: 10.1109/NAFIPS.2005.1548499.
- [57] Y. Bai e D. Wang. "Fundamentals of Fuzzy Logic Control – Fuzzy Sets , Fuzzy Rules and Defuzzifications". Em: *Advanced Fuzzy Logic Technologies in Industrial Applications* (2006), pp. 334 –351. ISSN: 21931577. DOI: 10.1007/978-1-84628-469-4_2.
- [58] Y. Lei, Z. He, Y. Zi e Q. Hu. "Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs". Em: *Mechanical Systems and Signal Processing* 21.5 (2007), pp. 2280–2294. ISSN: 08883270. DOI: 10.1016/j.ymsp.2006.11.003.

- [59] K.-S. Wang, V. S. Sharma e Z.-Y. Zhang. "SCADA data based condition monitoring of wind turbines". Em: *Advances in Manufacturing* 2.1 (2014), pp. 61–69. ISSN: 2095-3127. DOI: 10.1007/s40436-014-0067-0. URL: <http://www.scopus.com/inward/record.url?eid=2-s2.0-84938903122{\&}partnerID=tZ0tx3y1>.
- [60] S. Hussain e H. a. Gabbar. "Vibration Analysis and Time Series Prediction for Wind Turbine Gearbox Prognostics". Em: *International Journal of Prognostics and Health Management* 4.Special Issue Wind Turbine PHM (2013), pp. 1–11. ISSN: 21532648.
- [61] D. Petković, Ž. Čojbašić e V. Nikolić. "Adaptive neuro-fuzzy approach for wind turbine power coefficient estimation". Em: *Renewable and Sustainable Energy Reviews* 28 (2013), pp. 191–195. ISSN: 13640321. DOI: 10.1016/j.rser.2013.07.049.
- [62] D. Petković, S. Shamshirband, N. B. Anuar, S. Naji, M. L. Mat Kiah e A. Gani. "Adaptive neuro-fuzzy evaluation of wind farm power production as function of wind speed and direction". Em: *Stochastic Environmental Research and Risk Assessment* 29.3 (2014), pp. 793–802. ISSN: 14363259. DOI: 10.1007/s00477-014-0901-8.
- [63] J. Yan, Y. Liu, S. Han e M. Qiu. "Wind power grouping forecasts and its uncertainty analysis using optimized relevance vector machine". Em: *Renewable and Sustainable Energy Reviews* 27 (2013), pp. 613–621. ISSN: 13640321. DOI: 10.1016/j.rser.2013.07.026. URL: <http://dx.doi.org/10.1016/j.rser.2013.07.026>.
- [64] T. Benkedjouh, K. Medjaher, N. Zerhouni e S. Rechak. "Health assessment and life prediction of cutting tools based on support vector regression". Em: *Journal of Intelligent Manufacturing* 26.2 (2015), pp. 213–223. ISSN: 15728145. DOI: 10.1007/s10845-013-0774-6.
- [65] J. Yu. "Machine health prognostics using the Bayesian-inference-based probabilistic indication and high-order particle filtering framework". Em: *Journal of Sound and Vibration* 358 (2015), pp. 97–110. ISSN: 10958568. DOI: 10.1016/j.jsv.2015.08.013. URL: <http://dx.doi.org/10.1016/j.jsv.2015.08.013>.
- [66] P. Baraldi, M. Compare, S. Sauco e E. Zio. "Ensemble neural network-based particle filtering for prognostics". Em: *Mechanical Systems and Signal Processing* 41.1-2 (2013), pp. 288–300. ISSN: 08883270. DOI: 10.1016/j.ymssp.2013.07.010. URL: <http://dx.doi.org/10.1016/j.ymssp.2013.07.010>.
- [67] E. Zio e F. Di Maio. "Fatigue crack growth estimation by relevance vector machine". Em: *Expert Systems with Applications* 39.12 (2012), pp. 10681–10692. ISSN: 09574174. DOI: 10.1016/j.eswa.2012.02.199. URL: <http://dx.doi.org/10.1016/j.eswa.2012.02.199>.

- [68] F. Di Maio, K. L. Tsui e E. Zio. "Combining Relevance Vector Machines and exponential regression for bearing residual life estimation". Em: *Mechanical Systems and Signal Processing* 31 (2012), pp. 405–427. ISSN: 08883270. DOI: 10.1016/j.ymssp.2012.03.011. URL: <http://dx.doi.org/10.1016/j.ymssp.2012.03.011>.
- [69] D. C. Vaz. "Tecnologias de Energias Renováveis I". Notas da disciplina. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2008.
- [70] C. D. Sequeira. "A análise de vibrações como ferramenta para a melhoria da manutenção em aerogeradores". Tese de doutoramento. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2012.
- [71] J. K. Kaldellis e D. Zafirakis. "The wind energy (r)evolution: A short review of a long history". Em: *Renewable Energy* 36.7 (2011), pp. 1887–1901. ISSN: 09601481. DOI: 10.1016/j.renene.2011.01.002.
- [72] I. E. Agency. "Technology roadmap - Wind energy". Em: *Technology Roadmap* (2013), p. 58. ISSN: 1557-170X. DOI: 10.1007/SpringerReference_7300.
- [73] M. I. Blanco, M. Bolinger, R. Wiser, T. K. Boomsma, N. Meade, S. E. Fleten, A. Myhr, C. Bjerkseter, A. Ågotnes, T. A. Nygaard e Willis Insurance. "The economics of wind energy". Em: *European Journal of Operational Research* 42.6-7 (2012), pp. 714–728. ISSN: 03772217. DOI: 10.1016/j.renene.2014.01.017.
- [74] World Wind Energy Association WWEA. "Annual 2012 report". Em: *Ue* (2012).
- [75] D. Franklin. *Megatech As grandes inovações do futuro*. The Economist Books, 2017. ISBN: 978-989-724-393-6.
- [76] EWEA. "Wind energy scenarios for 2030". Em: *Ewea* August (2015), pp. 1–8. ISSN: 1098-6596. DOI: 10.1017/CB09781107415324.004. arXiv: arXiv:1011.1669v3. URL: <http://www.ewea.org/fileadmin/files/library/publications/reports/EWEA-Wind-energy-scenarios-2030.pdf>.
- [77] F. P. García Márquez, A. M. Tobias, J. M. Pinar Pérez e M. Papaelias. "Condition monitoring of wind turbines: Techniques and methods". Em: *Renewable Energy* 46 (2012), pp. 169–178. ISSN: 09601481. DOI: 10.1016/j.renene.2012.03.003. URL: <http://dx.doi.org/10.1016/j.renene.2012.03.003>.
- [78] P. J. Tavner e F. Spinato. "Reliability of Different Wind Turbine Concepts with Relevance to Offshore Application". Em: *European Wind Energy Conference, Brussels* April (2008).
- [79] K. Kim, G. Parthasarathy, O. Uluyol e W. Foslien. "Use of SCADA data for failure detection in wind turbines". Em: *ASME 2011 5th International Conference on Energy Sustainability, ES 2011 PARTS A, B, AND C* (2011), pp. 2071–2079. DOI: 10.1115/ES2011-54243. URL: <http://www.scopus.com/inward/record.url?eid=>

- 2-s2.0-84881173549{\&}partnerID=40{\&}md5=36d0b3e0cb8b8dd9c0f0b338c7a17283{\%}
}5Cnhttp://www.nrel.gov/docs/fy12osti/51653.pdf.
- [80] T. Verbruggen. “Wind turbine operation and maintenance based on condition monitoring WT-Ω”. Em: *Technical Report, ECN-C-03-047*, April (2003). URL: <http://scholar.google.com/scholar?hl=en{\&}btnG=Search{\&}q=intitle:Wind+Turbine+Operation+{\&}+Maintenance+based+on+Condition+Monitoring+WT-?+Final+report{\#}0>.
- [81] A. S. de Baêna. “Análise de Temperaturas de Componentes para Controlo de Condição de Turbinas Eólicas”. Tese de Mestrado. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2016.
- [82] A. Kusiak e A. Verma. “Analyzing bearing faults in wind turbines: A data-mining approach”. Em: *Renewable Energy* 48, February 2017 (2012), pp. 110–116. ISSN: 09601481. DOI: 10.1016/j.renene.2012.04.020. URL: <http://dx.doi.org/10.1016/j.renene.2012.04.020>.
- [83] M. C. Garcia, M. a. Sanz-Bobi, J. del Pico e M. Cruz. “SIMAP: Intelligent System for Predictive Maintenance Application to the Health Condition Monitoring of a Wind Turbine Gearbox”. Em: *Computers in Industry* 57.6 (2006), pp. 552–568. ISSN: 01663615. DOI: 10.1016/j.compind.2006.02.011. URL: <http://linkinghub.elsevier.com/retrieve/pii/S0166361506000534>.
- [84] K. Kim, G. Parthasarathy, O. Uluyol, W. Foslien, S. Sheng e P. Fleming. “Use of SCADA Data for Failure Detection in Wind Turbines”. Em: *ASME 2011 5th International Conference on Energy Sustainability, Parts A, B, and C* October (2011), pp. 2071–2079. DOI: 10.1115/ES2011-54243. URL: <http://proceedings.asmedigitalcollection.asme.org/proceeding.aspx?articleid=1636958>.
- [85] P. B. Dao, W. J. Staszewski, T. Barszcz e T. Uhl. “Condition monitoring and fault detection in wind turbines based on cointegration analysis of SCADA data”. Em: *Renewable Energy* 116 (2018), pp. 107–122. ISSN: 18790682. DOI: 10.1016/j.renene.2017.06.089.
- [86] Himani e R. Dahiya. “Condition monitoring of wind turbine for rotor fault detection under non stationary conditions”. Em: *Ain Shams Engineering Journal* (2017). ISSN: 20904479. DOI: 10.1016/j.asej.2017.04.002. URL: <http://dx.doi.org/10.1016/j.asej.2017.04.002>.
- [87] S. Odojin, E. Bentley e D. Aikhuele. “Robust fault estimation for wind turbine energy via hybrid systems”. Em: *Renewable Energy* 120 (2018), pp. 289–299. ISSN: 18790682. DOI: 10.1016/j.renene.2017.12.031. URL: <https://doi.org/10.1016/j.renene.2017.12.031>.

- [88] P. Cross e X. Ma. “Nonlinear system identification for model-based condition monitoring of wind turbines”. Em: *Renewable Energy* 71 (2014), pp. 166–175. ISSN: 09601481. DOI: 10.1016/j.renene.2014.05.035. URL: <http://dx.doi.org/10.1016/j.renene.2014.05.035>.
- [89] H. D. M. De Azevedo, A. M. Araújo e N. Bouchonneau. “A review of wind turbine bearing condition monitoring: State of the art and challenges”. Em: *Renewable and Sustainable Energy Reviews* 56 (2016), pp. 368–379. ISSN: 18790690. DOI: 10.1016/j.rser.2015.11.032. URL: <http://dx.doi.org/10.1016/j.rser.2015.11.032>.
- [90] E. J. Alvarez e A. P. Ribaric. “An improved-accuracy method for fatigue load analysis of wind turbine gearbox based on SCADA”. Em: *Renewable Energy* 115 (2018), pp. 391–399. ISSN: 18790682. DOI: 10.1016/j.renene.2017.08.040. URL: <http://dx.doi.org/10.1016/j.renene.2017.08.040>.
- [91] N. Troldborg e J. Sørensen. “A simple atmospheric boundary layer model applied to large eddy simulations of wind turbine wakes”. Em: *Wind Energy* 17.April 2013 (2014), pp. 657–669. ISSN: 1099-1824. DOI: 10.1002/we. arXiv: arXiv:1006.4405v1. URL: <http://onlinelibrary.wiley.com/doi/10.1002/we.1608/full>.
- [92] J. Herp, M. H. Ramezani, M. Bach-Andersen, N. L. Pedersen e E. S. Nadimi. “Bayesian state prediction of wind turbine bearing failure”. Em: *Renewable Energy* 116 (2018), pp. 164–172. ISSN: 18790682. DOI: 10.1016/j.renene.2017.02.069.
- [93] Z. Song, Z. Zhang, Y. Jiang e J. Zhu. “Wind Turbine Health State Monitoring Based on a Bayesian Data-driven Approach”. Em: *Renewable Energy* (2018). ISSN: 09601481. DOI: 10.1016/j.renene.2018.02.096. arXiv: linkinghub.elsevier.com/retrieve/pii/S0960982205000989 [http:]. URL: <http://linkinghub.elsevier.com/retrieve/pii/S0960148118302404>.
- [94] Z. Tian, T. Jin, B. Wu e F. Ding. “Condition based maintenance optimization for wind power generation systems under continuous monitoring”. Em: *Renewable Energy* 36.5 (2011), pp. 1502–1509. ISSN: 09601481. DOI: 10.1016/j.renene.2010.10.028. URL: <http://dx.doi.org/10.1016/j.renene.2010.10.028>.
- [95] A. Kusiak e A. Verma. “Analyzing bearing faults in wind turbines: A data-mining approach”. Em: *Renewable Energy* 48.April (2012), pp. 110–116. ISSN: 09601481. DOI: 10.1016/j.renene.2012.04.020. URL: <http://dx.doi.org/10.1016/j.renene.2012.04.020>.
- [96] P. Bangalore e L. B. Tjernberg. “An approach for self evolving neural network based algorithm for fault prognosis in wind turbine”. Em: *2013 IEEE Grenoble Conference PowerTech, POWERTECH 2013* (2013). DOI: 10.1109/PTC.2013.6652218.

- [97] P. Bangalore e M. Patriksson. "Analysis of SCADA data for early fault detection, with application to the maintenance management of wind turbines". Em: *Renewable Energy* 115 (2018), pp. 521–532. ISSN: 18790682. DOI: 10.1016/j.renene.2017.08.073. URL: <https://doi.org/10.1016/j.renene.2017.08.073>.
- [98] B. Chen, P. C. Matthews e P. J. Tavner. "Wind turbine pitch faults prognosis using a-priori knowledge-based ANFIS". Em: *Expert Systems with Applications* 40.17 (2013), pp. 6863–6876. ISSN: 09574174. DOI: 10.1016/j.eswa.2013.06.018. URL: <http://dx.doi.org/10.1016/j.eswa.2013.06.018>.
- [99] Y. Sinha e J. A. Steel. "Failure Prognostic Schemes and Database Design of a Software Tool for Efficient Management of Wind Turbine Maintenance". Em: *Wind Engineering* 39.4 (2015), pp. 453–477. ISSN: 0309-524X. DOI: 10.1260/0309-524X.39.4.453. URL: <http://journals.sagepub.com/doi/10.1260/0309-524X.39.4.453>.
- [100] M. A. Djeziri, S. Benmoussa e R. Sanchez. "Hybrid method for remaining useful life prediction in wind turbine systems". Em: *Renewable Energy* 116 (2018), pp. 173–187. ISSN: 18790682. DOI: 10.1016/j.renene.2017.05.020. URL: <http://dx.doi.org/10.1016/j.renene.2017.05.020>.
- [101] P. Mazidi, L. Bertling Tjernberg e M. A. Sanz Bobi. "Wind turbine prognostics and maintenance management based on a hybrid approach of neural networks and a proportional hazards model". Em: *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability* 231.2 (2017), pp. 121–129. ISSN: 17480078. DOI: 10.1177/1748006X16686899.
- [102] X. Fan, X. Yang, X. Li e J. Wang. "A Particle-Filtering Approach for Remaining Useful Life Estimation of Wind Turbine Gearbox". Em: *International Conference on Chemical, Material and Food Engineering* (2015), pp. 198–200. DOI: 10.2991/cmfe-15.2015.47.
- [103] J. K. Lee, J. Y. Park, K. Y. Oh, S. H. Ju e J. S. Lee. "Transformation algorithm of wind turbine blade moment signals for blade condition monitoring". Em: *Renewable Energy* 79.1 (2015), pp. 209–218. ISSN: 18790682. DOI: 10.1016/j.renene.2014.11.030. URL: <http://dx.doi.org/10.1016/j.renene.2014.11.030>.
- [104] R. Ruiz de la Hermosa González-Carrato. "Wind farm monitoring using Mahalanobis distance and fuzzy clustering". Em: *Renewable Energy* 123 (2018), pp. 526–540. ISSN: 18790682. DOI: 10.1016/j.renene.2018.02.097.
- [105] T. M. Welte e K. Wang. "Models for lifetime estimation: an overview with focus on applications to wind turbines". Em: *Advances in Manufacturing* 2.1 (2014), pp. 79–87. ISSN: 21953597. DOI: 10.1007/s40436-014-0064-3.

- [106] G. d.N. P. Leite, A. M. Araújo e P. A. C. Rosas. “Prognostic techniques applied to maintenance of wind turbines: a concise and specific review”. Em: *Renewable and Sustainable Energy Reviews* 81.February 2017 (2018), pp. 1917–1925. ISSN: 18790690. DOI: 10.1016/j.rser.2017.06.002.
- [107] Y. Hu, H. Li, X. Liao, E. Song, H. Liu e Z. Chen. “A probability evaluation method of early deterioration condition for the critical components of wind turbine generator systems”. Em: *Mechanical Systems and Signal Processing* 76-77 (2016), pp. 729–741. ISSN: 10961216. DOI: 10.1016/j.ymssp.2016.02.001. URL: <http://dx.doi.org/10.1016/j.ymssp.2016.02.001>.
- [108] NORDEX. “N80/2500 N90/2300”. Em: (2016), p. 8. URL: http://www.nordex-online.com/fileadmin/MEDIA/Produktinfos/EN/Nordex{_}N90{_}2300{_}GB.pdf.
- [109] J. C. Dunn. “A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters”. Em: *Journal of Cybernetics* 3.3 (1973), pp. 32–57. ISSN: 00220280. DOI: 10.1080/01969727308546046.
- [110] J. C. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Ed. por Springer. 1983. ISBN: 978-1-4757-0452-5.
- [111] B. Mauch, J. Apt, P. M. S. Carvalho e M. J. Small. “An effective method for modeling wind power forecast uncertainty”. Em: *Energy Systems* 4.4 (2013), pp. 393–417. ISSN: 1868-3967. DOI: 10.1007/s12667-013-0083-3. URL: <http://link.springer.com/10.1007/s12667-013-0083-3>.

Caso 3

Sabendo que no dia 40 de 2011 a caixa de velocidades da turbina 1 do parque eólico em estudo foi alvo de reparação, temos que $R = 5760$.

Reduzindo os dados recolhidos para valores de velocidade do rotor $\in [9.6, 16.9]$ rpm resulta num $R = 3788$. A distribuição de valores de $Velocidade_{rotor}$ e $Temperatura_{componente}$ podem ser vistas nos seguintes histogramas das Figuras A.1 e A.2.




Figura A.1: Histograma $Velocidade_{rotor}$.




Figura A.2: Histograma $Temperatura_{componente}$.

Limite Superior Variável β_2

Seguindo a equação $d = \frac{n_{max} - n_{min}}{0.5}$ temos que $d = 11$ bins. Aplicando a função do matlab histcounts a divisão dos valores de velocidade do rotor e temperatura do rolamento da caixa de velocidades por esses mesmos 11 bins é realizada, cuja distribuição pode ser observada na Figura A.3.




Figura A.3: Histograma distribuição dos dados pelos bins

A média dos valores de velocidade do rotor e de temperatura de rolamento da caixa de velocidades podem ser vistos na Tabela A.1.

Tabela A.1: Valores de média em cada bin

	Bins										
	1	2	3	4	5	6	7	8	9	10	11
VelocidadeRotor	10.00	10.33	10.83	11.29	11.78	12.28	12.77	13.28	13.78	14.30	14.89
TemperaturaRolamento	53.16	53.42	54.47	56.19	57.54	58.98	59.16	60.13	60.86	61.65	62.57

Por fim, com vista a obtermos a função $Temp(n)$, é utilizada uma regressão polinomial de segundo grau, da qual concluímos que $Temp(n) = -0.1874 * n^2 + 6.5626 * n + 5.6116$ cujo gráfico está presente na Figura A.4. Equação que nos permite obter o limite superior Variável β_2 .




Figura A.4: Gráfico da função $Temp(n) = -0.1874 * n^2 + 6.5626 * n + 5.6116$.

Limite Inferior Variável β_1

Após normalização da matriz de velocidade do rotor, o algoritmo Fuzzy C-means é aplicado. Utilizando a lógica fuzzy C-means, em que para efeitos de demonstração será utilizado o registo $R = 3500$ e iniciando com 2 clusters, obtemos:

$$Membership = \begin{bmatrix} 0.9988 & 0.9525 & 1 & 0.9715 & 0.3763 & 0.0018 & 0.0532 & 0.0340 \\ 0.0012 & 0.0475 & 0 & 0.0285 & 0.6237 & 0.9982 & 0.9468 & 0.9660 \end{bmatrix}$$

Resultando na seguinte distribuição das turbinas pelos 2 grupos (Tabela A.2),

Tabela A.2: Grupos de Turbinas Caso 3

Grupos de Turbinas pós-clustering					
Grupo 1			Grupo 2		
Turbina	Vrotor	Temp	Turbina	Vrotor	Temp
1	14.00	60.77	5	13.44	62.70
2	14.35	60.75	6	12.92	63.64
3	14.04	61.82	7	12.63	62.49
4	13.89	60.16	8	13.14	61.89

Tendo em atenção que a condição $\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$ é respeitada em ambos os grupos e lembrando que a turbina em estudo é a Turbina 1, situada no Grupo 1, então $T_{min} = 60.16 \text{ °C}$ correspondente ao *Limite Inferior Variável*, $\beta_1 = 60.16$ para o registo $R = 3500$.

Grau de deterioração g

Uma vez calculados os limites inferior e superior, o grau de deterioração o grau de deterioração em $R = 3500$, cuja *velocidadedorotor* = 14.00 rpm pode ser calculado de acordo com a equação A.1:

$$g(14.00) = \frac{x(14.00) - \beta_1(14.00)}{\beta_2(14.00) - \beta_1(14.00)} = \frac{60.77 - 60.16}{61.30 - 60.16} = 0.54, \quad (\text{A.1})$$

Relembrando a Tabela 3.4 verificamos que se encontra no intervalo $g \in [0.30, 0.55]$ o que revela um valor “Bom” do grau de deterioração.

Pela Figura A.5 é difícil retirar ilações, apenas que é possível identificar um grupo de valores de grau de deterioração acima de 1. No entanto, pela regressão linear de 2º grau apresentada no gráfico A.6 podemos ver uma tendência crescente do grau de deterioração aproximando-se de valores de alerta ou de perigo perto da data de reparação.




Figura A.5: Gráfico deterioração Caso 3.




Figura A.6: Regressão polinomial 2º grau Caso 3.

Caso 4

Temos que dia 42 de 2011 a caixa de velocidades da turbina 3 do parque eólico em estudo foi alvo de reparação, temos que $R = 6048$.

Reduzindo os dados recolhidos para valores de velocidade do rotor $\in [9.6, 16.9]$ rpm resulta num $R = 4068$. A distribuição de valores de $Velocidade_{rotor}$ e $Temperatura_{componente}$ podem ser vistas nos seguintes histogramas (Figuras B.1 e B.2).




Figura B.1: Histograma $Velocidade_{rotor}$.




Figura B.2: Histograma $Temperatura_{componente}$.

Limite Superior Variável β_2

Seguindo a equação $d = \frac{n_{max} - n_{min}}{0.5}$ temos que $d = 10$ bins. Aplicando a função do Matlab, histcounts a divisão dos valores de velocidade do rotor e temperatura do rolamento da caixa de velocidades por esses mesmos 10 bins é realizada, cuja distribuição pode ser observada na Figura B.3.




Figura B.3: Histograma distribuição dos dados pelos bins.

A média dos valores de velocidade do rotor e de temperatura de rolamento da caixa de velocidades podem ser vistos na Tabela B.1.

Tabela B.1: Valores de média em cada bin

	Bins									
	1	2	3	4	5	6	7	8	9	10
VelocidadeRotor	9.98	10.30	10.85	11.36	11.91	12.48	13.02	13.56	14.18	14.78
TemperaturaRolamento	55.37	54.90	57.08	58.64	60.34	62.54	63.37	63.48	66.18	67.18

Por fim, com vista a obtermos a função $Temp(n)$, é utilizada uma regressão polinomial de segundo grau, da qual concluímos que $Temp(n) = -0.1070 * n^2 + 5.2538 * n + 12.8958$ cujo gráfico está presente na Figura B.4. Equação que nos permite obter o limite superior Variável β_2 .




Figura B.4: Gráfico da função $Temp(n) = -0.1070 * n^2 + 5.2538 * n + 12.8958$.

Limite Inferior Variável β_1

Após normalização da matriz de velocidade do rotor, o algoritmo Fuzzy C-means é aplicado. Utilizando a lógica fuzzy C-means, em que para efeitos de demonstração será utilizado o registo $R = 3800$ e iniciando com 2 clusters, obtemos:

$$Membership = \begin{bmatrix} 0.2050 & 0.1076 & 0.3347 & 0.9974 & 0.8331 & 0.9701 & 0.9662 & 0.9670 \\ 0.7950 & 0.8924 & 0.6653 & 0.0026 & 0.1669 & 0.0299 & 0.0338 & 0.0330 \end{bmatrix}$$

Resultando na seguinte distribuição das turbinas pelos 2 grupos (Tabela B.2,

Tabela B.2: Grupos de Turbinas Caso 4

Grupos de Turbinas pós-clustering					
Grupo 1			Grupo 2		
Turbina	Vrotor	Temp	Turbina	Vrotor	Temp
4	14.27	70.95	1	14.47	63.63
5	14.37	61.55	2	14.73	61.28
6	14.22	76.99	3	14.45	70.96
7	14.22	76.64			
8	14.33	72.72			

Tendo em atenção que a condição $\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$ é respeitada em ambos os grupos e lembrando que a turbina em estudo é a Turbina 3, situada no Grupo 2, então $T_{min} = 61.28^\circ\text{C}$ correspondente ao *Limite Inferior Variável*, $\beta_1 = 61.28$ para o registo $R = 3800$.

Grau de deterioração g

Uma vez calculados os limites inferior e superior, o grau de deterioração o grau de deterioração em $R = 3800$, cuja *velocidadedorotor* = 14.45 rpm pode ser calculado de acordo com a equação B.1:

$$g(14.45) = \frac{x(14.45) - \beta_1(14.45)}{\beta_2(14.45) - \beta_1(14.45)} = \frac{70.96 - 61.28}{66.47 - 61.28} = 1.87, \quad (\text{B.1})$$

Relembrando o quadro (Tabela 3.4) verificamos que se encontra no intervalo $g \in [0.80, \text{inf}]$ o que revela um valor “Perigo” do grau de deterioração, que corresponde à expectativa uma vez que o componente foi substituído .

O gráfico (Figura B.5) não consegue revelar o que de facto se está a passar com o componente. Já através do gráfico presente na Figura B.6 é possível observar o aumento do grau de deterioração ao longo do registo, no entanto, revelando sempre valores um pouco acima do expectável ($[0.1]$), apresentando também no início uma tendência decrescente do grau de deterioração, o que na prática se traduz num melhoramento da condição do componente, que acaba por não fazer muito sentido, assumindo que nenhuma acções externas foram tomadas.




Figura B.5: Gráfico deterioração Caso 4.




Figura B.6: Regressão polinomial 2º grau Caso 4.

Caso 5

Uma vez que dia 38 de 2012 a caixa de velocidades da turbina 4 do parque eólico em estudo foi alvo de reparação, temos que $R = 5472$.

Reduzindo os dados recolhidos para valores de velocidade do rotor $\in [9.6, 16.9]$ rpm resulta num $R = 3189$. A distribuição de valores de $Velocidade_{rotor}$ e $Temperatura_{componente}$ podem ser vistas nos seguintes histogramas (Figuras C.1 e C.2).




Figura C.1: Histograma $Velocidade_{rotor}$.




Figura C.2: Histograma $Temperatura_{componente}$.

Limite Superior Variável β_2

Seguindo a equação $d = \frac{n_{max} - n_{min}}{0.5}$ temos que $d = 10$ bins. Aplicando a função do Matlab, histcounts a divisão dos valores de velocidade do rotor e temperatura do rolamento da caixa de velocidades por esses mesmos 10 bins é realizada, cuja distribuição pode ser observada na Figura C.3.




Figura C.3: Histograma distribuição dos dados pelos bins.

A média dos valores de velocidade do rotor e de temperatura de rolamento da caixa de velocidades podem ser vistos na Tabela C.1.

Tabela C.1: Valores de média em cada bin

	Bins									
	1	2	3	4	5	6	7	8	9	10
VelocidadeRotor	9.99	10.32	10.88	11.42	11.95	12.54	13.06	13.67	14.23	14.75
TemperaturaRolamento	54.79	54.81	58.05	59.47	60.28	61.70	62.43	63.44	64.88	67.49

Por fim, com vista a obtermos a função $Temp(n)$, é utilizada uma regressão polinomial de segundo grau, da qual concluímos que $Temp(n) = -0.0836 * n^2 + 4.5338 * n + 17.86$ cujo gráfico está presente na Figura C.4. Equação que nos permite obter o limite superior Variável β_2 .




Figura C.4: Gráfico da função $Temp(n) = -0.0836 * n^2 + 4.5338 * n + 17.86$.

Limite Inferior Variável β_1

Após normalização da matriz de velocidade do rotor, o algoritmo Fuzzy C-means é aplicado. Utilizando a lógica fuzzy C-means, em que para efeitos de demonstração será utilizado o registo $R = 3000$ e iniciando com 2 clusters, obtemos:

$$Membership = \begin{bmatrix} 0.8453 & 0.9967 & 0.0055 & 0.0488 & 0.8727 & 0.01768 & 0.0001 & 0.7122 \\ 0.1547 & 0.0033 & 0.9945 & 0.9512 & 0.1273 & 0.9824 & 0.9999 & 0.2878 \end{bmatrix}$$

Resultando na seguinte distribuição das turbinas pelos 2 grupos (Tabela C.2),

Tabela C.2: Grupos de Turbinas Caso 5

Grupos de Turbinas pós-clustering					
Grupo 1			Grupo 2		
Turbina	Vrotor	Temp	Turbina	Vrotor	Temp
1	14.51	63.55	3	14.37	67.53
2	14.56	66.72	4	14.29	61.23
5	14.71	64.46	5	14.38	69.75
8	14.49	65.08			
7	14.35	70.64			

Tendo em atenção que a condição $\Delta_n = n_{max(t)} - n_{min(t)} < 1 \text{ rpm}$ é respeitada em ambos os grupos e lembrando que a turbina em estudo é a Turbina 4, situada no Grupo 2, então $T_{min} = 61.23C$ correspondente ao *Limite Inferior Variável*, $\beta_1 = 61.23$ para o registo $R = 3000$.

Grau de deterioração g

Uma vez calculados os limites inferior e superior, o grau de deterioração o grau de deterioração em $R = 3000$, cuja *velocidadedorotor* = 14.29 rpm pode ser calculado de acordo com a equação C.1:

$$g(14.29) = \frac{x(14.29) - \beta_1(14.29)}{\beta_2(14.29) - \beta_1(14.29)} = \frac{61.23 - 61.23}{65.57 - 61.23} = 0, \quad (C.1)$$

Aqui, surge um dos pontos fracos deste algoritmo. Como podemos ver o grau de deterioração para o registo $R = 3000$ é 0. Isto acontece quando a temperatura mínima do grupo onde está inserida a turbina (no caso, grupo2) corresponde à temperatura da turbina em estudo (turbina 4). Isto leva a que o numerador da nossa função de deterioração, nomeadamente $g(n) = (x(n) - \beta_1(n))$, seja 0.

Os gráficos nas Figuras C.5 e C.6 são apresentados de seguido, chamando a atenção para os valores de $g(n) = 0$ que correspondem a casos identicos ao do apresentado ($R = 3000$).




Figura C.5: Gráfico deterioração Caso 5.




Figura C.6: Regressão polinomial 2º grau Caso 5.

